

UNIVERSIDADE DE LISBOA
FACULDADE DE CIÊNCIAS
DEPARTAMENTO DE ENGENHARIA GEOGRÁFICA, GEOFÍSICA E ENERGIA



**Aplicação de controlo preditivo a um sistema de
arrefecimento de uma sala de aula (ventilação natural e
mecânica): componente experimental**

Cristiano Filipe Tomé Lúcio

Mestrado Integrado em Engenharia da Energia e do Ambiente

Dissertação orientada por:
Professor Doutor Guilherme Carrilho da Graça
Professor Doutor Pedro Ferreira

2017

“Believe you can and you’re halfway there”

Theodore Roosevelt

Agradecimentos

Chegar ao momento desta dissertação de Mestrado Integrado em Engenharia da Energia e do Ambiente só foi possível graças a um vasto conjunto de pessoas.

Aos meus amigos de infância, um especial agradecimento por todos os momentos partilhados ao longo do nosso crescimento e pela força transmitida quando abracei esta nova etapa da minha vida. Foram sem dúvida um importante apoio nesta longa caminhada.

Aos amigos da faculdade, um agradecimento pelos momentos que juntos passámos durante estes cinco anos e pelo suporte mútuo nos momentos mais complicados.

Aos colegas do grupo de investigação de edifícios 2015/2016 por toda a ajuda prestada e pelos bons momentos partilhados ao longo deste último ano.

Ao professor Guilherme Carrilho da Graça e ao professor Pedro Ferreira, orientadores desta dissertação, agradeço todos os conhecimentos transmitidos, disponibilidade, equipamentos e softwares facultados para a realização deste projeto.

Ao Ricardo Miguel, um especial agradecimento por ter sido uma pessoa fundamental no meu percurso académico e pessoal.

Aos meus pais, Arlindo Lúcio e Lurdes Tomé, agradeço o investimento feito na minha educação, o amor, o apoio emocional e os princípios morais transmitidos. Foram o principal suporte ao longo de toda esta caminhada.

A toda a família, agradeço todo o carinho e educação transmitidos desde sempre.

À Claudia Ferreirinha, que foi um pilar importantíssimo nesta longa caminhada, agradeço todo o carinho, suporte, motivação e todos os momentos partilhados.

Resumo

A qualidade do ar e a temperatura adequada dos espaços interiores nos edifícios de serviços são uma exigência por parte dos ocupantes com crescente significado nos projectos de climatização e ventilação. As pessoas passam cada vez mais tempo em ambientes artificiais (edifícios, transportes, etc) e a melhoria e aumento dos serviços e comércio está também associado a um crescente uso de energia no setor dos edifícios. No entanto, pelo tradicional uso dos sistemas de climatização e ventilação, a exigência dos ocupantes leva a um considerável consumo de energia. Deste modo, surge a necessidade de investigar novos métodos de controlo destes sistemas de forma mais eficiente em relação às tradicionais. Com uma atuação inteligente, poderá associar-se a poupança de energia à melhoria da qualidade do ar e otimização da temperatura de conforto.

Este trabalho surge da necessidade de melhorar a qualidade de ar de uma sala de aula computacional do edifício C2 da FCUL. Para solucionar o problema, desenvolveu-se um sistema de controlo preditivo com base em redes neuronais para controlar um sistema de ventilação híbrido. Este sistema é composto por uma janela basculante elétrica e um ventilador reversível de baixo consumo de energia. Dado que adjacente à sala de aula em estudo se encontra um longo corredor que liga as extremidades do edifício C2, a reversibilidade do ventilador permite trocas de ar entre o corredor e a sala ou entre o exterior e a sala. No que respeita à janela basculante elétrica, esta pode ser aberta sem a atuação do ventilador, permitindo a ventilação natural e consequentemente uma significativa poupança de energia.

Este sistema é ainda composto por uma rede de sensores que permite medir em tempo real a temperatura, humidade relativa e CO₂ no interior da sala, no corredor e no exterior, bem como a ocupação no interior da sala. Através dos dados registados, o algoritmo desenvolvido calculará a melhor opção de controlo que, para um horizonte de previsão de duas horas, cumpra as restrições de qualidade de ar e temperatura de conforto imposto e transmite essa opção de controlo ao ventilador e à janela.

Palavras-Chave: Controlo preditivo baseado em modelos, rede neuronal, conforto térmico, qualidade de ar

Abstract

Indoor air quality and comfort temperature of indoor rooms in buildings are having an increasingly relevance in ventilation and climatization projects due to occupants' demand. Nowadays, people spent more time inside artificial environments (buildings, transports, etc) and the access to more and better services and commerce is connected to an increase in energy use in buildings. However, traditional use of ventilation and climatization systems and occupants' demand result in an increase in energy consumption. For that reason, it is imperative to develop new control methodologies for these systems to be more efficient comparatively to the traditional ones. With a smart control of ventilation and climatization systems, it could be possible to associate energy savings, improved indoor air quality and optimized comfort temperature.

This work arises from the need to improve indoor air quality in a classroom located in building C2 of FCUL campus. To solve this problem, it was developed a model based predictive control using artificial neural networks to control a natural and mechanical ventilation system. This system consists of a mechanized window and a low energy reversible fan. Adjacent to the classroom, there is a long corridor and due to the reversible characteristics of the fan, it is possible to exchange air between the corridor and the classroom or between the outside and the classroom. Considering the characteristics of the window, it is also possible to open it independently of the fan status, allowing natural ventilation and consequently a reduction on energy consumption.

This system is also composed by a network of sensors that measures temperature, relative humidity and CO₂ inside the classroom, in the corridor and outside, and occupancy inside the classroom. Through this data, the developed algorithm will determine the best control option that accomplishes the desired indoor air quality and comfort temperature for a prediction horizon of two hours and will transmit that control option to the fan and to the window.

Keywords: Model based predictive control, neural network, thermal comfort, indoor air quality

Índice

Agradecimentos	v
Resumo	vi
Abstract	vii
Índice de Figuras	x
Índice de Tabelas	xii
Simbologia e notações	xiii
Capítulo 1 - Introdução	1
1.1 Enquadramento	1
1.2 Objetivos	3
1.3 Organização da tese	4
Capítulo 2 – Conceitos teóricos	5
2.1 Comportamento térmico dos edifícios	5
2.1.1 Transferência de calor por condução	5
2.1.2 Transferência de calor por convecção	6
2.1.3 Transferência de calor por radiação	6
2.2 Necessidades térmicas de um edifício	6
2.3 Modelo de Conforto térmico adaptativo	8
2.4 Qualidade do ar interior	10
2.5 Controlo preditivo baseado em modelos	10
2.5.1 Modelo White-box	12
2.5.2 Modelo Black-box	13
2.5.3 Modelo Gray-box	15
2.6 Redes neuronais artificiais	16
2.6.1 Redes neuronais múltipla camada feedforward	17
2.6.2 Funções de ativação	18
2.6.3 Processos de aprendizagem	20
2.7 Rede neuronal de função de base radial	20
Capítulo 3 – Configuração experimental	21
3.1 Caso de estudo	21
3.2 Equipamento de monitorização	23
3.2.1 Arduino Uno e WiFi Shield	24
3.2.2 Sensores de temperatura e humidade relativa	25
3.2.3 Sensores de CO ₂	25
3.2.4 Contador de pessoas	26
3.2.5 Sensor de estado da porta	27
3.2.6 Estação meteorológica da FCUL	27
3.2.7 Base de dados climáticos exteriores	28

3.3 Componentes de controlo do sistema de ventilação	29
3.3.1 Ventilador reversível	29
3.3.2 Janela basculante elétrica	30
3.3.3 Componente de atuação do sistema	31
3.3.4 Modos de atuação do Sistema e disposição dos sensores	32
3.4 Arquitectura do sistema e protocolos de comunicação	32
3.4.1 Raspberry pi	33
3.4.2 Comunicação entre os dispositivos usados	34
3.4.3 Base de dados	35
Capítulo 4 – Treino da rede neuronal	37
4.1 Aquisição de dados	37
4.2 Definição dos modelos preditivos	38
4.3 Previsão da ocupação	41
Capítulo 5 – Definição dos objetivos de controlo	43
5.1 Função de custo	43
5.2 Método de Branch and Bound	44
Capítulo 6 – Resultados experimentais	47
Capítulo 7 – Conclusões	51
Referências	52
Anexo – A	54
Anexo – B	57

Índice de Figuras

Figura 1: Consumo final de energia na UE por sectores [1]	1
Figura 2: Resultados observados e previstos para edifícios: a) com AVAC e b) NV [11]	9
Figura 3: Norma de conforto adaptativo proposta para edifícios ventilados naturalmente	9
Figura 4: Estratégia do controlo preditivo baseado em modelos [13]	11
Figura 5: Estrutura básica do controlo preditivo baseado em modelos [13]	11
Figura 6: Fluxo de dados nos modelos White-box [16]	13
Figura 7: Fluxo de dados nos modelos Black-box [15]	15
Figura 8: Modelo RC simplificado de um edifício [22]	16
Figura 9: Fluxo de dados nos modelos Gray-box [15]	16
Figura 10: Estrutura de uma rede neuronal de múltipla camada feedforward [8]	18
Figura 11: Função limite [8]	19
Figura 12: Função sigmóide [8]	19
Figura 13: Diagrama da aprendizagem supervisionada [8]	20
Figura 14: Localização da sala de aula do Campus da FCUL em estudo	22
Figura 15: Interior da sala de aula em estudo	22
Figura 16: Ventilador visto do interior da sala	23
Figura 17: Corredor adjacente à sala de aula em estudo	23
Figura 18: Arduino Uno R3 (a) e Arduino WiFi Shield (b)	24
Figura 19: Sensor de temperatura e humidade relativa SHT15	25
Figura 20: Sensor de CO2 K30	25
Figura 21: Contador de pessoas	26
Figura 22: Software de contagem de pessoas	27
Figura 23: Posição da estação meteorológica da FCUL em relação à sala em estudo	28
Figura 24: Posição da estação meteorológica do WU em relação à FCUL	29
Figura 25: Ventilador e atenuador da France Air usados no projeto	30
Figura 26: Janela basculante elétrica	30
Figura 27: Relay Shield usada neste projeto	31
Figura 28: Funcionamento de uma relay electromagnético	31
Figura 29: Disposição dos sensores e configurações com o ventilador ligado	32
Figura 30: Arquitetura do sistema usado neste trabalho	33
Figura 31: Raspberry pi 2 Modelo B	33
Figura 32: Relação entre as tabelas na base de dados	36
Figura 33: Variação da temperatura interior na sala durante a aquisição de dados no dia 21, 22 e 23 de junho de 2016	37
Figura 34: Variação da concentração de CO2 na sala durante a aquisição de dados no dia 21, 22 e 23 de junho de 2016	38
Figura 35: Estrutura não-linear da RBFNN	39
Figura 36: Erro de teste vs erro de simulação para os modelos testados para a temperatura interior ...	39
Figura 37: Erro de teste vs erro de simulação para os modelos testados para o CO2 interior	40
Figura 38: Funções de custo para: a) temperatura interior e b) qualidade do ar interior	44
Figura 39: Fluxograma para definição do valor final da função de custo	44
Figura 40: Variação da temperatura interior em função da atuação do sistema para o fim de semana de 12 e 13 de novembro	47
Figura 41: Variação da concentração de CO2 interior em função da atuação do sistema para o fim de semana de 12 e 13 de novembro	48

Figura 42: Função de custo para o fim de semana de 12 e 13 de novembro	48
Figura 43: Variação da temperatura interior em função da atuação do sistema nos dias 15, 16 e 17 de novembro.....	49
Figura 44: Variação da concentração de CO ₂ interior em função da atuação do sistema nos dias 15, 16 e 17 de novembro	50
Figura 45: Função de custo para os dias 15, 16 e 17 de novembro	50
Figura 46: Variação da temperatura interior na sala durante a aquisição de dados no dia 23 e 24 de junho de 2016	54
Figura 47: Variação da concentração de CO ₂ na sala durante a aquisição de dados no dia 23 e 24 de junho de 2016.....	54
Figura 48: Variação da temperatura interior na sala durante a aquisição de dados no dia 27 e 28 de junho de 2016	55
Figura 49: Variação da concentração de CO ₂ na sala durante a aquisição de dados no dia 27 e 28 de junho de 2016.....	55
Figura 50: Variação da temperatura interior na sala durante a aquisição de dados no dia 29 e 30 de junho de 2016	56
Figura 51: Variação da concentração de CO ₂ na sala durante a aquisição de dados no dia 29 e 30 de junho de 2016.....	56

Índice de Tabelas

Tabela 1: Tolerância dos sensores de CO ₂ K30 [32].....	26
Tabela 2: Características da estação meteorológica da FCUL	28
Tabela 3: Características do ventilador tubular axial Helipac da France Air	29
Tabela 4: Características do Raspberry pi 2 Modelo B	34
Tabela 5: Atrasos temporais usados para os modelos preditivos selecionados para temperatura interna (Tint) e para a concentração de CO ₂ interior (CO ₂ int)	40
Tabela 6: Atrasos temporais das variáveis exógenas	41
Tabela 7: Previsão para a ocupação.....	41
Tabela 8: Modelos de previsão para a temperatura interior – teste 1 a 19	57
Tabela 9: Modelos de previsão para a temperatura interior – teste 20 a 38	58
Tabela 10: Modelos de previsão para a temperatura interior – teste 39 a 50	59
Tabela 11: Modelos de previsão para a concentração do CO ₂ interior – teste 51 a 69	60
Tabela 12: Modelos de previsão para a concentração do CO ₂ interior – teste 70 a 88	61
Tabela 13: Modelos de previsão para a concentração do CO ₂ interior – teste 89 a 107	62
Tabela 14: Modelos de previsão para a concentração do CO ₂ interior – teste 108 a 117.....	63
Tabela 15: Modelos de previsão para a temperatura exterior – teste 1 a 19.....	64
Tabela 16: Modelos de previsão para a temperatura exterior – teste 20 a 34.....	64
Tabela 17: Modelos de previsão para a temperatura no corredor – teste 1 a 19.....	65
Tabela 18: Modelos de previsão para a temperatura no corredor – teste 20 a 32.....	65
Tabela 19: Modelos de previsão para a concentração de CO ₂ no corredor – teste 1 a 19.....	66
Tabela 20: Modelos de previsão para a concentração de CO ₂ no corredor – teste 20 a 32	66

Simbologia e notações

FCUL – Faculdade de Ciências da Universidade de Lisboa

UE – União Europeia

GBPN – *Global Building Performance Network*

BPIE – *Building Performance Institute Europe*

AVAC – Aquecimento, Ventilação e Ar Condicionado

PMV – *Predicted Mean Vote*

PPD – *Predicted percent dissatisfied*

NV – Ventilação Natural

RECS – Regulamento de Desempenho Energético dos Edifícios de Comércio e Serviços

RC – Resistências e Condensadores

RBFNN – Rede Neuronal de Função de Base Radial

LM – Algoritmo de Levenberg-Marquardt

API – *Application programing interface*

HTTP – *Hypertext transfer protocol*

Capítulo 1 - Introdução

1.1 Enquadramento

Os edifícios são responsáveis por uma significativa percentagem do consumo de energia em todo o mundo. Segundo dados da União Europeia (UE), os edifícios são responsáveis por 41% do consumo total de energia [1]. Por este motivo, várias políticas de combate às alterações climáticas têm-se focado neste sector.

De acordo com *Global Building Performance Network* (GBPN) [2], a mudança de políticas energéticas até 2050 poderá resultar na redução dos consumos no sector dos edifícios em cerca de 30% face aos consumos verificados atualmente, tendo em conta que no mesmo período é esperado um aumento de 130% da área de superfície dos edifícios face à actual.

Em 2011, segundo dados da *Building Performance Institute Europe* (BPIE) [3], 25% dos edifícios existentes na Europa eram não-residenciais, sendo que 28% da totalidade destes edifícios eram de retalho, 23% de escritórios, 17% eram edifícios educacionais, hotéis, restaurantes e espaços desportivos. Outras atividades representavam os restantes 32% dos edifícios.




Figura 1: Consumo final de energia na UE por sectores [1]

O aumento da população, a melhoria e aumento da procura dos serviços existentes na sociedade actual e o facto das pessoas passarem cada vez mais tempo no interior de edifícios contribuiu fortemente para o aumento do consumo de energia neste sector. Adicionalmente, as exigências dos ocupantes com as condições de conforto térmico nos edifícios entram em conflito com a necessidade de redução do consumo energético dos mesmos. Com esta divergência surge a necessidade de otimizar os sistemas de climatização e ventilação, uma vez que estes representam a principal fonte de consumo energético nos edifícios residenciais e não-residenciais [4].

Os sistemas de climatização e ventilação têm como propósito criar um ambiente térmico que vá ao encontro das exigências dos ocupantes e das actividades realizadas nesses espaços, bem como favorecer a qualidade do ar interior. Isto torna-se importante dado que se estima que as pessoas passem 90% do seu tempo em ambientes artificiais (habitação, local de trabalho, transportes, entre outros) [5].

O conceito de “síndrome do edifício doente” é consequência de deficientes processos de ventilação que resultam em alta geração de poluentes e baixas taxas de renovação do ar. Nestas situações, verifica-se uma baixa qualidade do ar interior que poderá ter impacto na saúde, conforto, bem-estar e produtividade dos ocupantes [6].

Os problemas de ventilação podem ser resolvidos com recurso à ventilação mecânica, ventilação natural (NV) ou ventilação híbrida. Contudo, devido às políticas energéticas emergentes desde as crises do

petróleo na década de 70, vários estudos têm sido desenvolvidos sobre ventilação natural por forma a dominar e aumentar a aplicação da mesma nos novos edifícios. No entanto, em climas como o de Portugal, nos meses mais quentes, os sistemas mecânicos tornam-se indispensáveis para os edifícios não-residenciais.

Para ajudar a ultrapassar estes problemas, a implementação de tecnologias de informação e comunicação têm dado um importante contributo, levando o edifício a denominar-se por “edifício inteligente”. Isso significa que certas componentes do edifício possam ser controladas com recurso a valiosos dados obtidos através das tecnologias mencionadas e a tomada de decisões sem a intervenção humana. No entanto, um edifício inteligente não é apenas um edifício onde a instalação e operação de tecnologias facilita o seu funcionamento diário. Este conceito pressupõe que o edifício funcione de uma forma mais eficiente, fornecendo melhores condições ambientais interiores com menor consumo de energia [7].

Para isso, em particular no que respeita à atuação de sistemas de climatização e ventilação, têm sido desenvolvidos recentemente vários estudos onde estes sistemas são controlados com recurso a controlo preditivo baseados em redes neuronais. As redes neuronais consistem em metodologias computacionais inspiradas nas redes de neurónios biológicas do ser humano. Estas redes têm de passar por um processo de treino que ao ser bem-sucedido, possibilita a realização de tarefas de previsão, classificação ou reconhecimento de padrões, permitindo assim que sejam aplicadas na resolução de vários problemas científicos e de engenharia [8]. Estes modelos constituem a base do sistema de controlo preditivo a implementar que tendo a capacidade de prever ocorrências futuras, permite a tomada imediata de decisões para evitar, por exemplo, sobreaquecimento de uma sala de aula ou escritório numa situação de taxa de ocupação e temperatura exterior mais elevadas.

Esta dissertação surgiu da necessidade de melhorar as condições interiores de uma sala computacional do edifício C2 da FCUL. Dada a intensa utilização desta sala, foram detetados deficientes níveis de ventilação. Para solucionar este problema, optou-se por recorrer a equipamentos de baixo custo e baixo consumo de energia, que serão apresentados no capítulo 3.

1.2 Objetivos

Esta dissertação tem como principal objetivo desenvolver uma abordagem de controlo preditivo para um sistema de arrefecimento de baixo consumo de energia para uma sala de aula no campus da FCUL.

O controlo preditivo será feito através da leitura de dados da sala em tempo real (ocupação no interior da sala e temperatura, humidade relativa e dióxido de carbono no interior da sala, no corredor adjacente e no exterior), atuação de um ventilador reversível e de uma janela basculante elétrica.

Para tal, foram instalados na sala sensores ligados a micro-controladores (*Arduinos*) para a leitura dos dados em tempo real, um *Arduino* composto por uma relé (*Relay Shield*) ligado ao quadro elétrico para a atuação do ventilador e da janela, uma câmara de processamento de imagem para contagem de pessoas (*People Counter*) para determinar a ocupação e um sensor na porta para saber o estado da mesma. Este foi o primeiro objetivo e a primeira fase deste projeto.

O segundo objetivo consistiu na obtenção de dados da dinâmica térmica da sala para posterior treino dos modelos preditivos. Este treino foi feito com recurso a dados resultantes da atuação do ventilador e da janela elétrica com estados aleatórios e ocupação aleatória.

Adquiridos os dados, o terceiro objetivo consistiu em construir modelos preditivos para a temperatura e concentração de dióxido de carbono no interior da sala.

Como quarto objetivo, procedeu-se à determinação de uma função de custo de modo a dar um critério de atuação ao sistema. Esta função de custo visa que a atuação do sistema provoque um equilíbrio entre a temperatura e a qualidade do ar interior, mantendo-os o mais próximo possível dos valores de referência.

Por fim, o quinto e último objetivo consistiu em atuar o sistema tendo em conta os modelos preditivos construídos e a estratégia implementada para escolha da atuação do sistema (método de *Branch and Bound*).

1.3 Organização da tese

A organização deste trabalho será feita do seguinte modo:

- No capítulo 2, serão abordados os principais processos de transferência de calor e as necessidades térmicas dos edifícios, será abordado o modelo de conforto térmico usado neste trabalho e os requisitos de qualidade do ar segundo a regulamentação portuguesa, será feito um breve resumo do que consiste um controlo preditivo baseado em modelos, os tipos de modelos existentes e algumas das suas características. Aqui, serão também abordadas as principais características e elementos das redes neuronais bem como a rede e o algoritmo usado neste trabalho.
- No capítulo 3, serão analisados todos os equipamentos usados, os protocolos de comunicação entre os dispositivos e a arquitetura final do sistema.
- No capítulo 4, será abordada a aquisição dos dados para o treino das redes neuronais e a construção dos modelos preditivos.
- No capítulo 5, serão definidos os objetivos de controlo do sistema e o método usado para escolha da melhor atuação do sistema de ventilação (método de *Branch and Bound*)
- No capítulo 6, serão apresentados os resultados experimentais.
- No capítulo 7, serão apresentadas as conclusões do trabalho desenvolvido e uma curta análise do potencial trabalho futuro.
- Por fim, este trabalho conta ainda com uma secção de referências bibliográficas e uma secção de anexos.

Capítulo 2 – Conceitos teóricos

Neste capítulo, começar-se-á por abordar os principais fatores de transferência de calor nos edifícios e os fatores que influenciam o balanço térmico dos mesmos. De seguida, será abordado o modelo de conforto térmico usado e as restrições de qualidade de ar segundo a legislação portuguesa. De seguida será abordada a estrutura básica dos modelos de controlo preditivos, os vários modelos preditivos existentes e a respetiva comparação entre os modelos. Serão ainda apresentados alguns trabalhos com a aplicação dos diferentes modelos. Na sub-seções seguinte, será dada especial atenção às redes neuronais artificiais uma vez que constituem a estrutura fundamental deste trabalho. Aqui, serão abordadas as suas principais características e os elementos básicos comuns a alguns algoritmos de redes neuronais artificiais. Por fim, no último sub-capítulo será apresentada a rede neuronal usada neste trabalho e o algoritmo usado para o treino da mesma.

2.1 Comportamento térmico dos edifícios

Um edifício funciona como um filtro ao ambiente exterior, possibilitando um ambiente artificial favorável às atividades neles desenvolvidas. Sendo um filtro ao ambiente exterior, o edifício encontra-se exposta a vários tipos de perturbações, sejam elas internas, resultantes dos ocupantes e dos equipamentos elétricos existentes, sejam elas externas, como a temperatura exterior, radiação solar, humidade relativa, entre outras.

Devido às perturbações mencionadas, geram-se diferentes temperaturas em diferentes pontos. Pelos princípios da termodinâmica, há uma constante transferência de calor quer no interior do edifício, quer do próprio edifício com o exterior. A transferência de calor é realizada pelos seguintes mecanismos: condução, convecção e radiação.

2.1.1 Transferência de calor por condução

A transferência de calor por condução resulta do transporte de energia num meio devido a um gradiente de temperatura. O fluxo de calor transmitido unidireccionalmente por unidade de área é dado pela lei de Fourier [9]:

$$q_{cond} = -k \frac{dT}{dx} \quad (1)$$

Onde:

q_{cond} – fluxo de calor por condução por unidade de área [W/m²]

k – condutividade térmica de um material [W/(m.K)]

$\frac{dT}{dx}$ – gradiente de temperatura entre dois pontos do material [K/m]

O sinal negativo indica o sentido em que se dá a transferência de calor, que é feita no sentido do corpo de menor temperatura.

2.1.2 Transferência de calor por convecção

A transferência de calor por convecção consiste na energia transferida entre uma superfície e um fluido em movimento sobre essa superfície. A transferência de calor por convecção por unidade de área é dada pela lei de Newton do arrefecimento [9]:

$$q_{conv} = h_c(T_s - T_\infty) \quad (2)$$

Onde:

q_{conv} – fluxo de calor por convecção por unidade de área [W/m²]

h_c – coeficiente de transferência de calor por convecção [W/(m².K)]

T_s – temperatura da superfície [K]

T_∞ - temperatura do fluido fora da camada limte [K]

2.1.3 Transferência de calor por radiação

Qualquer corpo (sólido, líquido ou gasoso) emite radiação caso a sua temperatura seja superior ao zero absoluto (0 K). A emissão de radiação por parte de um corpo deve-se às mudanças na configuração dos eletrões dos átomos ou moléculas que constituem esse corpo. A energia do campo radiativo é transmitida por fotões e ao contrário da condução e da convecção, a transferência de energia por radiação não necessita de um meio [9]. Assim, a transferência de calor por radiação entre dois corpos é dada por [9]:

$$q_{rad} = h_r(T_{s1} - T_{s2}) \quad (3)$$

Onde:

q_{rad} – fluxo de calor por radiação por unidade de área [W/m²]

h_r – coeficiente de transferência de calor por radiação [W/(m².K)]

T_{s1} – temperatura da superfície 1 [K]

T_{s2} – temperatura da superfície 2 [K]

2.2 Necessidades térmicas de um edifício

Pelas constantes trocas de calor existentes, importa estudar de que forma estas condicionam as necessidades térmicas do balanço energético do edifício com a finalidade de criar condições térmicas propícias às atividades desenvolvidas. De um modo simplificado, o balanço térmico do edifício é dado pela seguinte equação:

$$G_i + G_s + G_v + G_c = \rho C_p V_s \frac{\delta T_i}{\delta t} + \sum_{n=1}^k A_n U_n (T_i - T_{sn}) \quad (4)$$

Onde:

G_i – ganhos internos [W]

G_s – ganhos solares [W]

$G_v = \rho C_p \dot{V}(T_{ext} - T_{int})$ – ganhos por ventilação [W]

$G_c = \rho C_p \dot{V}(T_{ins} - T_{int})$ – ganhos por climatização [W]

$\rho C_p V_s \frac{\delta T_i}{\delta t}$ – energia armazenada no ar interior [W]

$\sum_{n=1}^k A_n U_n (T_i - T_{sn})$ – transferência de calor pela envolvente do edifício [W]

ρ – massa volúmica do fluido [kg/m³]

V_s – volume do fluido [m³]

C_p – calor específico do fluido [J/(kg.K)]

$\frac{\delta T_i}{\delta t}$ – variação da temperatura para um intervalo

\dot{V} – caudal volúmico [m³/s]

de tempo [K/s]

T_{ext} – temperatura do ar exterior [K]

A_n – área de superfície [m²]

T_{int} – temperatura do ar interior [K]

U_n – coeficiente de transmissão térmica da

T_{ins} – temperatura de insuflação do ar climatizado [K]

superfície n [W/(m².K)]

O balanço térmico diverge significativamente dos edifícios residenciais para os edifícios de comércio e serviços. Nestes últimos, sobre o qual incide este trabalho, há geralmente muitos ganhos internos devido à ocupação, iluminação e equipamentos elétricos e devido ao contínuo melhoramento do isolamento das envolventes, no inverno gera-se o calor necessário para manter temperaturas de conforto, mas em dias mais quentes, surgem necessidades de arrefecimento [10].

Estas necessidades de arrefecimento podem ser atingidas de duas formas: usando sistemas de ventilação (natural, mecânico ou híbrido) ou sistemas de climatização.

A ventilação natural resulta de duas componentes: o vento, devido às diferenças de pressão na fachada do edifício e a flutuabilidade do ar, devido à diferença de temperatura do ar. A componente controlada pelo vento é inconstante devido à intensidade e direcção do vento, enquanto a flutuabilidade do ar, apesar de ter uma intensidade inferior quando comparada com o vento, é mais constante devido à estratificação do ar nos espaços interior [10].

A ventilação natural tem a potencialidade de colmatar uma significativa parte das necessidades de arrefecimento e de ar novo nos edifícios de serviços e comércio inseridos em climas amenos, como o de Portugal. Para mais, um sistema mecânico de ventilação tem um consumo energético na ordem dos 5-15 W/m², podendo ser comparável com os sistemas de iluminação [10].

Comparativamente a um sistema AVAC, que representam um consumo de 50%-60% do consumo total do edifício, fica então clara a potencialidade que um sistema de ventilação natural e mecânico devidamente dimensionado tem na redução das necessidades de arrefecimento e de ar novo de um edifício [10].

2.3 Modelo de Conforto térmico adaptativo

Para avaliar o conforto térmico, existem essencialmente dois modelos: o modelo desenvolvido por Fanger (PMV-PPD) e o modelo de conforto adaptativo.

Neste trabalho, a definição da banda de conforto térmico na sala em estudo foi feita recorrendo-se ao modelo de conforto adaptativo. O modelo pretende combinar o ambiente interior, fatores psicofísicos e psicológicos que produzam condições térmicas aceitáveis para 80% ou mais dos ocupantes [11].

A norma de conforto adaptativo proposta para a *ASHRAE Standard 55* pode ser aplicada para as seguintes situações [11]:

- Espaços naturalmente condicionados onde a regulação térmica é feita pelos ocupantes através da abertura e fecho de janelas.
- Os espaços podem conter sistemas de aquecimento, mas quando estiverem em uso, esta norma não é aplicada.
- Os espaços não podem conter sistemas mecânicos de arrefecimento, como ar-condicionados ou arrefecimento radiativo.
- Os espaços podem conter ventilação mecânica, mas a abertura e fecho de janelas deverá ser a primeira forma de regulação térmica.
- Os ocupantes devem estar numa atividade próxima da sedentária (1-1.3 Met).

A sensação térmica das pessoas é baseada no modelo de balanço de calor do corpo humano que prevê a sensação térmica recorrendo a fatores como a temperatura, humidade, radiação térmica, velocidade do ar, tipo de atividade e vestuário. Em alternativa ao PMV, que se baseia no modelo descrito, o modelo de conforto adaptativo indica que fatores para além dos mencionados podem ter um impacto na expectativa e preferência térmica das pessoas [11]. Apesar do modelo da transferência de calor do corpo humano conseguir lidar com adaptação comportamental (alteração de vestuário, atividade ou velocidade do ar dos sistemas AVAC), este modelo não consegue lidar com a componente psicológica da adaptação. Este fator tem especial relevância em edifícios naturalmente ventilados [11].

Outro aspeto relevante para o desenvolvimento do modelo de conforto adaptativo foi a possibilidade de abertura de janelas em edifícios não-residenciais. Pelas elevadas restrições de conforto impostas inicialmente pela *ASHRAE Standard 55* (antes da inclusão do modelo de conforto adaptativo), era difícil cumprir os requisitos de conforto sem apoio mecânico. Associado a isto estão os elevados consumos de energia para manter o conforto térmico segundo os rigorosos limites impostos [11].

Pessoas que diariamente trabalham ou vivem em ambientes onde a abertura de janelas é permitida, ficam expostas a maiores variações térmicas interiores. Analogamente, a sua percepção térmica e tolerância alargam-se [11].

Para definição do modelo de conforto adaptativo, foram recolhidos 22 mil dados de 160 países localizados em 4 continentes. Estes dados incluíam respostas a um questionário térmico, estimativas metabólicas e de vestuário, medições do ambiente interno, observações meteorológicas exteriores e uma variedade de índices térmicos calculados. Posteriormente, estes dados foram separados consoante os edifícios tivessem sistema AVAC ou apenas ventilação natural através da abertura de janelas por parte dos ocupantes [11].

Da análise dos dados, surgem dois padrões relevantes. Conforme mostra a Figura 2, os ocupantes dos edifícios com AVAC têm uma menor capacidade de se adaptarem às variações da temperatura exterior enquanto os ocupantes de edifícios com NV têm uma banda de adaptação superior. Relativamente à

comparação com o modelo do PMV, nos edifícios com AVAC há uma excelente previsão das temperaturas de conforto. Para os edifícios com NV, a diferença entre a previsão do PMV e os valores observados reflecte a existência de fatores que não são considerados pelo PMV, como por exemplo, os fatores psicofísicos e psicológicos [11].




Figura 2: Resultados observados e previstos para edifícios: a) com AVAC e b) NV [11]

Tendo em conta estes dados, foi proposta uma alternativa ao tradicional PMV para inclusão na *ASHRAE Standard 55*. Esta alternativa, o modelo de conforto adaptativo, é dado em função da temperatura média mensal exterior e a temperatura de conforto interior é dada pela seguinte equação [11]:

$$T_{conf} = 0.31T_{out} + 17.8 \text{ (}^{\circ}\text{C)} \quad (5)$$




Figura 3: Norma de conforto adaptativo proposta para edifícios ventilados naturalmente

Comparativamente com as relações dos modelos PMV-PPD, estes indicam que um grupo de indivíduos que expressem um voto médio da sensação térmica ± 0.5 ou ± 0.85 em relação às três classificações centrais (-1,0,1), é expectável que 10% ou 20% dos indivíduos estejam fora destas classificações. Aplicando estes critérios às regressões dos edifícios com ventilação natural, obtêm-se duas bandas de zona de conforto média para 90% de aceitabilidade e 80% de aceitabilidade dos ocupantes. O resultado está ilustrado na Figura 3, onde a temperatura de conforto foi obtida através da equação (5). Para 90% de aceitabilidade, tem-se uma banda de 5°C, enquanto para 80% de aceitabilidade se tem uma banda de 7°C [11].

2.4 Qualidade do ar interior

A qualidade do ar interior tem especial impacto nas atividades desenvolvidas. Esta tem um impacto directo na saúde, no conforto e produtividade dos ocupantes. Um dos problemas detetados na sala de aula em estudo foram altas concentrações de CO₂, indicando assim uma deficiente ventilação do espaço e uma baixa qualidade do ar.

Segundo a portaria nº353-A/2013 [12], referente ao Regulamento de Desempenho Energético dos Edifícios de Comércio e Serviços (RECS), o caudal mínimo de ar novo deve ser calculado de tal forma que não se atinja o limiar de proteção de concentração de CO₂ durante o período de ocupação, sendo este limiar de proteção de 1250 ppm. O regulamento indica ainda que, num período de 8 horas consecutivas, a média da concentração do CO₂ não deve exceder os 1625 ppm.

2.5 Controlo preditivo baseado em modelos

O tradicional controlo dos sistemas AVAC leva a que o funcionamento destes sistemas seja inconstante e/ou muitas vezes por períodos de tempo e em ocasiões desnecessárias.

O controlo preditivo baseado em modelos, com origem nos finais da década de 70, é uma estratégia de controlo optimizado com base em modelos preditivos e otimização [13].

Esta metodologia de controlo consiste numa estratégia onde o modelo do processo sob controlo está explicitamente definido e o sinal da tomada de ação resulta da minimização de uma função de custo, tendo em consideração as restrições ou limitações do processo em questão [13]. A aplicação de modelos de controlo preditivo a sistemas de climatização e ventilação de edifícios visa atingir principalmente dois objectivos: a maximização do conforto nos espaços interiores e a qualidade de ar dos mesmos e a diminuição do consumo de energia.

Para atingir estes objetivos, os sistemas de controlo preditivos baseados em modelos revelam-se ser mais adequados dada a sua capacidade de prever futuros valores de temperatura ou concentrações de CO₂ tendo em consideração as perturbações internas e externas. As perturbações internas ocorrem devido à atividade dos ocupantes, iluminação e uso de equipamentos elétricos. Por outro lado, as perturbações externas devem-se à temperatura exterior, humidade relativa e radiação solar. As perturbações internas podem ser dadas a conhecer ao sistema sabendo previamente o tipo de uso do espaço em estudo. Relativamente às perturbações externas, estas podem ser determinadas com recurso a modelos de previsão de curto ou médio prazo [14].

Para uma correcta e eficiente aplicação de um controlo preditivo baseado em modelos num edifício, este deve ter as seguintes componentes [15]:

- Modelo dinâmico do edifício em tempo real
- Previsão das principais perturbações
- Medida de desempenho que permita alcançar os objetivos
- Algoritmo de optimização em tempo real

As abordagens de controlo preditivo baseado em modelos seguem a estratégia representada na Figura 4 e descrita de seguida [13]:




Figura 4: Estratégia do controlo preditivo baseado em modelos [13]

1. As saídas futuras no horizonte de previsão N , são previstas a cada instante t através dos modelos desenvolvidos para a previsão das diferentes variáveis. Essas saídas previstas $y(t+k | t)$ ¹ para $k = 1 \dots N$ dependem do valor no instante t e do futuro sinal de controlo $u(t+k | t)$, $k=0 \dots N-1$.
2. O sinal de controlo futuro é calculado otimizando um determinado critério de forma a manter o processo o mais próximo possível da trajetória de referência. Dada a vasta área de aplicabilidade do controlo preditivo baseado em modelos, em determinados casos o critério referido pode tomar a forma de uma função quadrática do erro entre a saída prevista e a trajetória de referência prevista, enquanto noutros casos o custo das ações de controlo ao longo do horizonte de previsão é incluído na função de custo.
3. Segundo o principio do horizonte de recuo, apenas o sinal de controlo do primeiro instante $u(t+1 | t)$ é enviado para o processo enquanto que o restante sinal de controlo calculado é descartado. Em instantes futuros, todo o processo se repete de forma a usar um sinal de controlo otimizado em cada instante.

Assim, a estrutura básica para implementar esta estratégia de controlo apresenta-se na Figura 5.

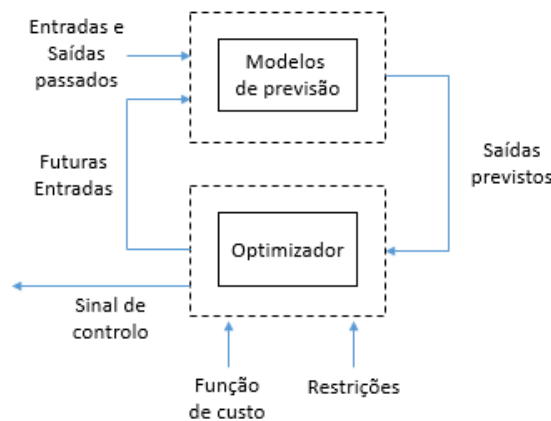


Figura 5: Estrutura básica do controlo preditivo baseado em modelos [13]

O modelo preditivo desenvolvido determinará as futuras saídas tendo em conta os valores actuais e passados das variáveis de controlo. No optimizador, várias alternativas de tomada de ação são propostas

¹ Notação indica o valor da variável no instante $t+k$ calculada no instante t

e são enviadas para o modelo prever a respetiva saída. As previsões da saída, são usadas na função de custo de forma a que o sistema possa escolher a alternativa que minimize a função de custo acumulada ao longo do horizonte de previsão.

A função de custo é uma função que traduz matematicamente o custo de uma determinada ação em relação a outra. Esta função é definida tendo em conta o caso de estudo, podendo refletir o consumo de energia, custo da energia, distanciamento de uma variável aos limites admitidos, entre outras, quando aplicado ao caso dos edifícios. O objetivo do controlo preditivo baseado em modelos é minimizar esta função em cada instante, escolhendo sempre a ação de controle que minimize a função de custo e que, portanto, é a mais eficiente para cumprir os objetivos ao longo do horizonte considerado.

As principais vantagens desta abordagem de controlo para a automação de processos em edifícios, nomeadamente processos relacionados com os sistemas de climatização e ventilação, está na capacidade de previsão das futuras saídas, capacidade de lidar com restrições, incertezas, sistemas variáveis temporalmente, várias possibilidades de atuação do sistema e uso de uma função de custo com vista ao cumprimento de múltiplos objetivos [16].

Por outro lado, a utilização desta abordagem obriga à criação de um ou mais modelos relativos ao edifício em causa, pois cada edifício tem as suas próprias características, sejam elas a construção, a exposição solar, o clima onde estão inseridos, o perfil de ocupação, o tipo de atividade, entre outros fatores [15]. Construir os modelos para automação de processos é a fase do projeto que mais tempo consome. Nas sub-seções que se seguem, passam a analisar-se as três principais estruturas usadas para a criação de modelos de controlo preditivo: Modelo *White-box*, Modelo *Black-box* e Modelo *Gray-box*.

2.5.1 Modelo *White-box*

Os modelos *White-box* são baseados nos princípios físicos dos processos em questão. Para o caso dos edifícios, baseiam-se nas equações da dinâmica térmica dos edifícios e dos seus sistemas de energia. O número de parâmetros a ter em consideração é elevado e isso traz algum nível de complexidade a estes modelos. Permite prever corretamente a dinâmica do edifício, mas pela sua complexidade leva a que os modelos sejam de difícil formulação e computacionalmente muito demorados [15].

Estes modelos são geralmente usados em *softwares* como EnergyPlus® e TRNSYS® e requerem como dados de entrada as condições meteorológicas exteriores, a estrutura do edifício em estudo, as suas condições fronteira, os sistemas energéticos existentes e o tipo de actividade desenvolvida. Com base nas equações dos modelos físicos da dinâmica térmica dos edifícios podem determinar-se parâmetros como o desempenho energético ou os níveis de conforto térmico [16]. A figura que se segue (Figura 6) ilustra o fluxo de informação num modelo *White-box*.

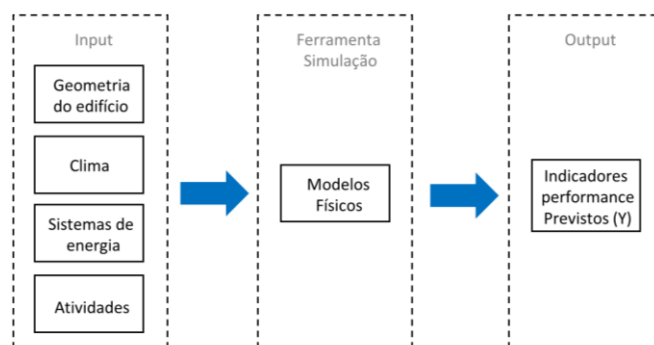


Figura 6: Fluxo de dados nos modelos *White-box* [16]

No trabalho em [17], o autor desenvolve um controlo preditivo baseado em modelos criando uma interação entre o software EnergyPlus, onde prevê o resultado de uma determinada ação de controlo com base nas equações da física dos edifícios e o Matlab®, onde procura diferentes ações para executar aquela que minimize a função de custo e atualiza os parâmetros a introduzir no software de simulação para o instante seguinte.

Este trabalho, [17], tem como finalidade controlar a abertura mecânica de várias janelas, favorecendo o arrefecimento passivo do edifício (aproveitando, por exemplo, estratégias de arrefecimento nocturno) e atinge uma poupança de energia no sistema de climatização que poderá ser superior a 40%. O horizonte preditivo usado é de 24 horas, sendo que o procedimento é recalculado a cada 2 horas.

De acordo com estudos já efetuados com estas ferramentas de simulação [18], verifica-se a sua precisão e robustez. No entanto, estas simulações requerem muita informação detalhada que é necessário introduzir nos modelos e que nem sempre está disponível, como a radiação solar e direção e velocidade do vento, perfil e tipo de ocupação, equipamentos elétricos nos espaços em questão, entre outros. Requerem também conhecimento científico na área muito desenvolvido para a implementação dos modelos e a resolução das equações do modelo requerem um processamento computacional elevado, sendo esta a principal desvantagem para utilização em controlo e operação de sistemas de ventilação e climatização [16].

2.5.2 Modelo *Black-box*

Os modelos *Black-box* são conhecidos como modelos puramente baseados em dados. Estes tipos de modelos requerem medições no local para aquisição de dados durante um determinado período de tempo para posterior treino dos modelos. Este treino visa dotar os modelos de capacidade para prever futuros acontecimentos tendo em conta os vários estados do sistema e variáveis de controlo. No caso dos edifícios, devido à sua dinâmica perante diferentes condições ambientais externas e devido ao tipo de atividade que dentro dele se realiza, as medições efetuadas antes do treino do modelo têm como objetivo dar-lhe conhecer as características do edifício [15].

Como principais vantagens, estes modelos dependem apenas dos dados e não de um grande conjunto de parâmetros da física dos processos e a sua complexidade computacional depois de treinados é inferior quando comparados com os modelos *White-box*. Isto torna-os mais fáceis de integrar em controlo preditivo baseado em modelos havendo uma substancial redução no processamento computacional.

Após o treino dos modelos que consiste num ajuste de uma função matemática linear ou não-linear aos valores adquiridos previamente, estes modelos requerem medições em tempo real durante a execução para que as previsões sejam ajustadas a cada instante aos valores reais, tornando assim a previsão bastante precisa [15].

Os modelos de black-box aplicados a edifícios, seja para previsão do consumo de energia, seja para atuar sistemas AVAC para melhorar o conforto térmico dos ocupantes, são na maioria dos casos construídos com recursos a redes neuronais artificiais. Este será o modelo implementado neste trabalho.

No trabalho [19], o autor usa uma abordagem com base em redes neuronais para controlar um sistema AVAC. As redes neuronais são utilizadas para desenvolver o modelo preditivo para a temperatura e humidade relativa no interior bem como do conforto térmico, através do índice do PMV, de uma sala de aula para um horizonte de previsão de 4 horas, sendo que a cada 5 minutos o procedimento é recalculado. Tendo em conta a previsão para o horizonte considerado, no instante em questão é definido a temperatura de insuflação do sistema AVAC que permita manter o conforto térmico com um PMV inferior a 0.5 ou superior a -0.5, consumindo a menor quantidade de energia possível, de forma a minimizar a função de custo definida pelo autor.

Em [20], o autor desenvolve uma rede neuronal para prever a procura de energia de um edifício no sudeste de Espanha. Esta rede neuronal tem como entrada a temperatura exterior, a radiação solar, o estado dos vários equipamentos do sistema AVAC, o tipo de dia da semana e a energia produzida pelo sistema PV do edifício. Os modelos foram desenvolvidos e testados para vários horizontes de previsão, em especial para $N=1$ minuto e $N=60$ minutos, tendo ambos demonstrado uma ótima precisão, quando comparados com os valores de consumo medidos.

No trabalho [21], a rede neuronal desenvolvida visa prever a iluminação num edifício de escritórios. Para tal, 3 meses de dados foram adquiridos. A rede neuronal usa como entrada a data e hora, a temperatura exterior, humidade relativa exterior, radiação solar e informação da radiação UV e aspetos arquitetónicos do edifício, como a distância às janelas dos sensores, o número de janelas, a orientação das salas e a dimensão das mesmas. Neste trabalho não é feita previsão para um determinado horizonte. Tratando-se apenas de um trabalho de modelação, uma vez mais a rede neuronal teve um desempenho ótimo, pois 98% dos dados previstos corresponderam aos dados medidos.

A revisão destes três trabalhos desenvolvidos na área de edifícios permite comprovar a robustez, flexibilidade e fiabilidade dos modelos Black-box, através de redes neuronais, para aplicação em controlo preditivo, previsão de variáveis ou caracterização e modelação de processos dinâmicos nos edifícios.

Estes modelos são de fácil implementação e de rápida computação. Contudo, precisam de ser treinados antes de controlar sistemas e a aquisição de dados para o treino é um processo demorado. As medições têm de ser feitas com bastante rigor para que o sistema consiga, futuramente, interpretar os acontecimentos com a maior precisão possível. A figura 7 ilustra o funcionamento destes modelos.

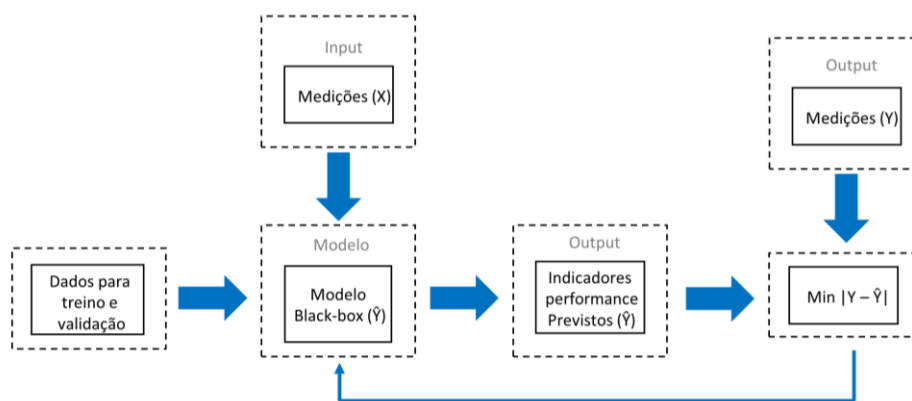


Figura 7: Fluxo de dados nos modelos *Black-box* [15]

2.5.3 Modelo *Gray-box*

Os modelos *Gray-box* são uma combinação dos dois tipos de modelos já apresentados. Estes modelos usam equações simplificadas para descrever a dinâmica do edifício, por exemplo baseadas nas redes de resistências e condensadores (RC). A quantidade de dados necessários para treinar o modelo é muito inferior em relação ao modelo *black-box* [15].

Nestes modelos, os condensadores representam a capacidade térmica das superfícies do edifício e as resistências representam a resistência térmica da envolvente do edifício. Com isto, estes modelos conseguem com alguma precisão captar a transferência de calor pelas envolventes do edifício e simular a dinâmica do mesmo [16]. Apesar de ter algum fundamento físico em relação ao modelo *Black-box*, continua a ser um modelo onde toda a dinâmica do edifício não é inteiramente conhecida. Uma ótima integração deste modelo requer longos períodos de computação para otimização dos parâmetros da rede RC e conhecimentos científicos na área da dinâmica térmica dos edifícios para a construção dos modelos.

No trabalho [22], o autor desenvolveu um modelo *Gray-box* para prever a carga de arrefecimento para um edifício. Os parâmetros da rede RC criados para caracterizar os modelos físicos do edifício são estimados com recurso a regressões não-lineares usando dados adquiridos localmente. Segundo o autor, dados referentes a uma ou duas semanas são suficientes para o treino do modelo. A Figura 8 mostra o modelo simplificado usado para caracterizar a dinâmica térmica do edifício em estudo.

Ainda em [22], usando dados gerados por simulação detalhada, o modelo simplificado teve a capacidade de igualar a carga horária com um erro de aproximadamente 2%. Quando aplicado num caso real, o modelo conseguiu prever as cargas horárias de arrefecimento para um período de quatro semanas com um erro de 9%.

simples células de computação denominadas por neurónios ou unidades de processamento [8]. O processamento dos neurónios é definido por uma função matemática vulgarmente conhecida por função de ativação.

Uma rede neuronal pode ser definida como um processador distribuído em paralelo constituído por unidades de processamento simples que têm a capacidade de adquirir conhecimento experimental e utilizar dessa capacidade para um determinado objetivo. Isto assemelha-se ao cérebro humano em dois aspectos. O conhecimento é adquirido através de processos de aprendizagem e os pesos entre as diferentes ligações interneuronais, conhecidos por pesos sinápticos, bem como os parâmetros dos neurónios, são usados para armazenar a aprendizagem adquirida [8].

O processo de treino da rede neuronal confere-lhe a capacidade de generalização após ajuste dos parâmetros [8]. Esta capacidade permite que a rede neuronal continue a produzir razoáveis saídas mesmo que os valores de entrada não tenham sido dados a conhecer durante o processo de treino.

As redes neuronais têm as seguintes capacidades e propriedades [8]:

- Não-linearidade: A rede neuronal pode ser linear ou não-linear. Caso a função matemática que implementa os neurónios seja não-linear, a rede terá um comportamento não-linear. Esta propriedade é importante se os mecanismos físicos reponsáveis pelos dados de entrada forem também não-lineares, como é o caso da dinâmica térmica dos edifícios.
- Sequência entrada – saída: A aprendizagem com um professor ou aprendizagem supervisionada consiste em modificar ou ajustar os pesos sinápticos bem como os parâmetros da função de ativação, aplicando um conjunto de exemplos de treino. Estes exemplos consistem em dados de entrada únicos e o correspondente valor de resposta desejado. Os dados são selecionados aleatoriamente e os parâmetros são ajustados na maioria dos casos de forma a minimizar a soma do quadrado das diferenças entre o valor de resposta desejado e o valor de resposta produzido pela rede neuronal. Este treino é então repetido até a rede atingir um estado estável onde as variações dos parâmetros deixam de ter relevância.
- Adaptatividade: As redes neuronais têm a capacidade de adaptar os parâmetros perante variações no ambiente envolvente. Uma rede neuronal treinada para atuar num ambiente específico pode ser reajustada para lidar com pequenas variações que possam existir no atual ambiente de operação. Quando operada em ambientes não-estacionários, a rede neuronal pode ser criada para ajustar os parâmetros em tempo real. Quanto mais adaptativo o sistema for, maior estabilidade e robustez terá para operar em sistemas não-estacionários.

Nas sub-seções que se seguem será feito um breve resumo sobre uma classe específica de redes neuronais, das funções de ativação usadas e dos processos de aprendizagem.

2.6.1 Redes neuronais múltipla camada *feedforward*

A estrutura de uma rede neuronal está relacionada com o algoritmo de aprendizagem usado para treinar a rede. As três principais estruturas são: camada simples *feedforward*, múltipla camada *feedforward* e rede recorrente [8]. Neste trabalho usou-se uma estrutura múltipla camada *feedforward*.

Esta estrutura é caracterizada pela presença de camadas ocultas (*hidden layer*), sendo a componente computacional denominada por “neurónio oculto”. O termo oculto deve-se ao facto desta parte da rede neuronal não ser vista nem pela entrada nem pela saída da rede. A camada de entrada é a camada responsável pela recepção dos estímulos exteriores, disponibilizando-os à primeira camada oculta. A

camada oculta tem com função aplicar uma transformação não-linear ao espaço de entrada, gerando um espaço oculto, onde a camada de saída consegue mais facilmente resolver o problema através de uma soma pesada linear, o que não é possível no espaço de entrada quando o espaço é não-linear. Adicionando uma ou mais camadas ocultas, a rede tem mais capacidade para modelar não-linearidades mais complexas. Isto permite que a rede represente melhor o processo para o qual foi treinada através de um conjunto extra de ligações sinápticas e uma maior dimensão de interações neuronais [8].

A Figura 10 ilustra a estrutura deste tipo de redes.




Figura 10: Estrutura de uma rede neuronal de múltipla camada *feedforward* [8]

2.6.2 Funções de ativação

A função de ativação define a saída do neurónio tendo em conta as suas sinapses. Existem vários tipos de funções de ativação como por exemplo, a função limite, a função sigmóide e a função gaussiana [8].

2.6.2.1 Função limite

A função limite é definida por:

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases} \quad (6)$$

Como consequência, a saída de um neurónio que seja constituído por uma função de ativação limite é expresso por:

$$y_k = \begin{cases} 1 & \text{se } v_k \geq 0 \\ 0 & \text{se } v_k < 0 \end{cases} \quad (7)$$




Figura 11: Função limite [8]

2.6.2.2 Função sigmóide

A função sigmóide é caracterizada por ter uma forma de “S” e é a função de ativação mais usada para a constituição de um neurónio numa rede neuronal do tipo percetão multicamada. Um exemplo de uma função sigmóide é a função logística, permitindo assim um equilíbrio entre um comportamento linear e não-linear do neurónio [8]. Esta função é dada pela seguinte equação:

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (8)$$

Na equação (8), a representa o declive da função sigmóide. Enquanto a função limite assume apenas o valor 0 ou 1, a função sigmóide assume um conjunto de valores entre 0 e 1, como mostra a Figura 12.




Figura 12: Função sigmóide [8]

Em determinadas situações, é desejável que a função de ativação tome valores entre -1 e 1. Nesses casos, a função sigmoide pode ser definida pela função da tangente hiperbólica [8] (equação (10)), enquanto a função limite sofre a seguinte alteração (equação (9)):

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v = 0 \\ -1 & \text{se } v < 0 \end{cases} \quad (9)$$

$$\varphi(v) = \tanh(v) \quad (10)$$

2.6.2.3 Função gaussiana

Para determinados tipos de redes neuronais de múltipla camada *feedforward*, como é o caso da rede neuronal de função de base radial que será apresentada mais à frente, uma das funções de ativação mais usadas toma a forma de uma função gaussiana. Esta função, é dada pela equação que se segue:

$$\varphi(x_j) = e^{-\frac{1}{2\sigma_i^2}\|x_j - c_i\|_2^2} \quad (11)$$

Onde $\|x_j - c_i\|_2^2$ representa a norma euclidiana centrada no ponto c_i

2.6.3 Processos de aprendizagem

Existem várias classes de métodos de aprendizagem para ajustar os parâmetros das redes neuronais: métodos supervisionados, métodos não supervisionados e métodos semi-supervisionados. Aos dois primeiros, também se chama método de aprendizagem com professor e sem professor. No âmbito trabalho, a rede neuronal foi treinada com recurso à aprendizagem com professor. Este método de aprendizagem apresenta-se de seguida.

2.6.3.1 Aprendizagem com professor

O “professor” pode ser visto como a componente que possui o conhecimento do ambiente, sendo este conhecimento representado por conjuntos de dados entrada-saída [8]. A Figura 13 ilustra o processo de aprendizagem descrito neste tópico.

Este processo de aprendizagem é constituído por um ciclo fechado de um sistema com realimentação. Como medida de desempenho do sistema, pode-se usar a média do quadrado dos erros ou a soma do quadrado dos erros ao longo das amostras de treino [8].

Quando o professor e a rede neuronal são expostos a uma amostra de treino, o professor tem a capacidade de dar ao algoritmo a resposta desejada para essa amostra. Os parâmetros da rede serão ajustados sob influência da amostra de treino e do erro. O erro consiste na diferença entre a saída desejável e a saída ideal. O conhecimento do ambiente é transferido para a rede neuronal através do processo de treino, ficando depois armazenado na forma dos parâmetros da rede [8].

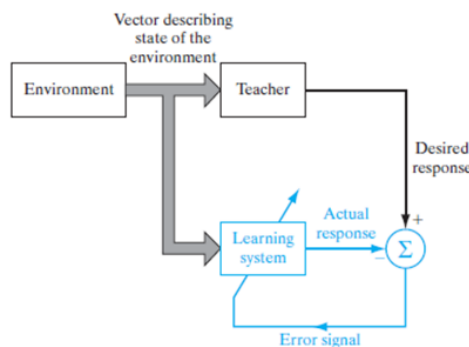


Figura 13: Diagrama da aprendizagem supervisionada [8]

2.7 Rede neuronal de função de base radial

A rede neuronal de função de base radial (RBFNN) é um tipo específico de rede neuronal de multicamada feedforward que usa na maioria dos casos a função de ativação gaussiana apresentada

anteriormente. Neste trabalho, os modelos preditivos foram definidos com recurso a este tipo de rede neuronal e para todas as variáveis para as quais se criaram modelos preditivos, apenas foi utilizada uma camada escondida. A primeira camada é constituída pelos dados de entrada que são ligados à camada oculta constituída por um conjunto de neurónios. A camada oculta, por sua vez, liga-se à camada de saída, onde são realizadas transformações lineares, produzindo assim o valor final de saída da rede [23].

No contexto deste trabalho, a rede neuronal atua como aproximadora de funções, fazendo um ajuste a uma curva num espaço multi-dimensional. Os dados de entrada, $X = \{x_j \in \mathbb{R}^m\}_{j=1}^N$, passam por um processo de transformações não-lineares nos neurónios da camada oculta, sendo os valores desejáveis de obter caracterizados por $Y = \{y_j \in \mathbb{R}\}_{j=1}^N$. Deste modo, a rede neuronal tem como função construir uma função tal que [23]:

$$y_j = f(x_j), f: \mathbb{R}^m \rightarrow \mathbb{R} \quad (12)$$

Para solucionar este problema de múltiplas variáveis, a RBFNN assume a seguinte forma [19]:

$$\hat{y}(x, w, C, \sigma) = \sum_{i=0}^n w_i \varphi_i(x, c_i, \sigma_i) \quad (13)$$

Nas RBFNN, a função de ativação não-linear mais usada é a função gaussiana, conforme a equação (11).

O processo de treino da RBFNN corresponde a determinar os valores w, C, σ para um determinado conjunto de dados de treino X^t de forma a minimizar a seguinte função [19]:

$$\Phi(X^t, w, C, \sigma) = \frac{1}{2} \|y - \hat{y}(X^t, w, C, \sigma)\|^2 \quad (14)$$

Para se determinar esses parâmetros, recorreu-se ao algoritmo de Levenberg-Marquardt (LM) [24] [25] utilizando um critério de treino modificado [26].

Visto que esta componente do trabalho sai um pouco do foco principal, para mais detalhes recomenda-se a leitura de [27], [28] e [29].

Capítulo 3 – Configuração experimental

Neste capítulo será apresentada a sala de aula em estudo, todo o *hardware* e *software* utilizado para a aquisição de dados em tempo real e serão apresentados os equipamentos de ventilação instalados na sala (ventilador reversível e janela elétrica basculante).

3.1 Caso de estudo

A sala de aula em estudo, sala 2.3.16, encontra-se na fachada sul do edificio C2 da Faculdade de Ciências da Universidade de Lisboa conforme mostra a Figura 14.




Figura 14: Localização da sala de aula do Campus da FCUL em estudo

A sala tem aproximadamente 65 m^2 , um pé direito de 3.5m e destina-se essencialmente a aulas computacionais, sendo que os ganhos internos se tornam superiores quando comparado com uma sala de aula convencional. Na Figura 15 e Figura 16 pode observar-se o interior da sala em estudo.



Figura 15: Interior da sala de aula em estudo



Figura 16: Ventilador visto do interior da sala

Adjacente à sala de aula, existe um longo corredor que liga os dois extremos do edifício C2 (Figura 17). Este corredor caracteriza-se por ter elevada inércia térmica, baixos ganhos solares e é naturalmente ventilado por quatro pontos de acesso.




Figura 17: Corredor adjacente à sala de aula em estudo

3.2 Equipamento de monitorização

Para monitorização da sala, seriam necessários equipamentos que permitissem a leitura de dados e posterior transmissão dos mesmos. Para tal, neste projeto optou-se por ligar os sensores de temperatura, humidade relativa e concentração de CO₂ a um micro-controlador (*Arduino Uno* com *WiFi Shield*). Para averiguar o estado da porta (aberta ou fechada), usou-se um *reed switch* conectado a um *Arduino Uno*. Por fim, para determinar a ocupação, foi instalada sobre a entrada uma câmara *Axis IP M3005-V* com o software *True View People Counter*.

Nas sub-secções que se seguem serão abordados com maior detalhe os diferentes equipamentos utilizados neste projeto.

3.2.1 Arduino Uno e WiFi Shield

Arduino é uma plataforma de código aberto que permite desenvolver projetos de instrumentação. Para tal, existem duas componentes: o *hardware* e o *software*. O *hardware* consiste numa placa de circuito programável constituída por um microcontrolador da família ATMEL AVR de 8 bits e o *software* permite escrever e fazer upload do código a partir de um computador. O *Arduino* usa uma linguagem de programação simplificada de C/C++, tornando mais acessível a sua programação. Para este projeto, foi usado o *hardware* *Arduino Uno R3*. Este *hardware* funciona em torno de um microcontrolador ATmega328P e é constituído por três tipos de memórias. A primeira, a memória *flash*, onde o código é guardado, dispõe da capacidade de 32 KB, dos quais 0.5 KB são usados pelo *bootloader*³. O microcontrolador dispõe também de uma memória SRAM (*Static Random Access Memory*) com capacidade de 2 KB onde são criadas e manipuladas as variáveis enquanto o código é executado (um pouco semelhante à RAM num computador). Por fim, dispõe de uma memória EEPROM (*Electrically Erasable Programmable Read-Only Memory*) com 1 KB de capacidade que permite que informações de longo prazo sejam armazenadas [30].




Figura 18: Arduino Uno R3 (a) e Arduino WiFi Shield (b)

O *Arduino* tem uma tensão de operação de 5V e através dos seus pinos pode fornecer energia a determinados dispositivos ligados a si (por exemplo, sensores) com uma tensão máxima de 5V ou 3.3V, sendo a corrente contínua máxima de 50mA para o pino de 3.3V e 20mA para o pino de 5V [30].

Ao *Arduino* podem ser ligados vários tipos de sensores e atuadores, podendo estes funcionar como entrada ou saída. A ligação entre o *Arduino* e os sensores que serão descritos na sub-secção seguinte foram realizadas através de comunicações *UART* (*Universal Asynchronous Receiver/Transmitter*). Este tipo de comunicação consiste numa ligação serie configurada para operar a um taxa de transmissão de 9600 bytes/s [30].

Para comunicar com outros dispositivos usou-se a *WiFi Shield* (Figura 18 b). Esta componente permite ligar o *Arduino* a uma rede de WiFi usando as normas 802.11b/g e suportando os tipos de encriptação *WEP* e *WPA2 Personal* [30].

³ Bootloader do microcontrolador do arduino consiste num firmware que permite instalar um novo firmware usando um programa exterior

3.2.2 Sensores de temperatura e humidade relativa

Para a monitorização da temperatura e da humidade relativa da sala de aula e do corredor, foram utilizados sensores SHT15 da *Sensirion* [31].



Figura 19: Sensor de temperatura e humidade relativa SHT15

Estes sensores possuem ainda uma componente de processamento de sinal que permite total calibração dos dados registados. Tanto o sensor de temperatura como o de humidade relativa encontram-se perfeitamente acoplados a um conversor de analógico para digital de 14bit, permitindo que a qualidade do sinal seja superior e o tempo de resposta inferior. Estes sensores possuem a vantagem de não serem sensíveis à radiação para efeitos de medição. Contudo, a sua exposição a elevada radiação solar pode resultar em diminuição do seu tempo de vida, pelo que não é aconselhada [31].

Nos gráficos abaixo apresentam-se as tolerâncias para os dois sensores.

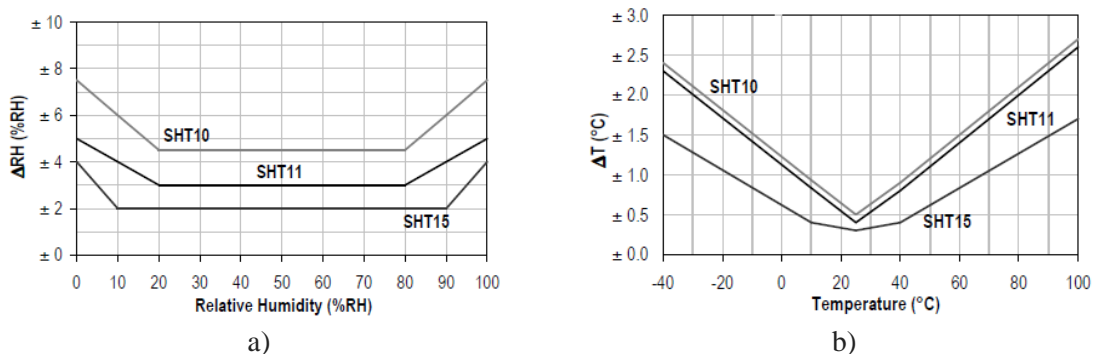


Gráfico 1: Tolerância do sensor de humidade relativa (a) SHT15 e sensor de temperatura (b) SHT15 [31]

3.2.3 Sensores de CO₂

Aos sensores de temperatura e humidade relativa, foi adicionalmente ligado, a cada *Arduino*, um sensor k30 de CO₂. [32].



Figura 20: Sensor de CO₂ K30

Este sensor de baixo custo, baixo consumo de energia e reduzidas dimensões permite uma fácil e discreta integração em sistemas de monitorização. A comunicação com o arduino é feita através de uma comunicação Serial UART, usando o protocolo Modbus [32].

As especificações deste sensor apresentam-se na Tabela 1.

Tabela 1: Tolerância dos sensores de CO₂ K30 [32]

Amplitude de medição	0 – 5000 ppm
Sensibilidade	$\pm 20 \text{ ppm} \pm 1\% \text{ valor medido}$
Precisão	$\pm 30 \text{ ppm} \pm 3\% \text{ valor medido}$

3.2.4 Contador de pessoas

Um dos principais focos da monitorização consiste em saber o número de pessoas no interior da sala num determinado instante. Para tal, foi colocada, no teto, junto da entrada, uma câmara *Axis M3005-V* com o software *TrueView People Counter*. Este software permite que a câmara se transforme num sensor, possibilitando a determinação em tempo real o número de ocupantes. Isto é possível através do API (*Application programming interface*) do software *TrueView People Counter* fazendo um pedido através do *http* (*Hypertext transfer protocol*) à câmara.



Figura 21: Contador de pessoas

O software *TrueView People Counter* foi desenvolvido para funcionar em câmaras *Axis IP* para ambientes onde a contagem de pessoas seja relevante para efeitos estatísticos. Quando instalado nas câmaras, não requer ligação a um computador, sendo a contagem feita autonomamente na câmara. O facto de a câmara poder ser acedida através de um endereço IP uma vez que está ligada fisicamente a uma rede *Ethernet*, permitem que todas as tarefas a realizar sejam mais eficientes, uma vez que tarefas como calibração, manutenção e recolha de dados podem ser feitas remotamente. A Figura 22 mostra o software instalado e a visão da câmara para o interior da sala.



Figura 22: Software de contagem de pessoas

3.2.5 Sensor de estado da porta

Para determinar o estado da porta foi ligado a um *Arduino Uno* um *reed switch*. Este dispositivo permitirá determinar os momentos em que a porta da sala se encontra aberta e fechada. O *reed switch* é formado por finíssimas lâminas envoltas num bulbo de vidro com um gás para evitar a sua corrosão. O material destas lâminas é sensível à acção do campo magnético e em condições normais, as lâminas encontram-se abertas, fazendo com que o circuito se abra e não exista passagem de corrente. Aquando da aproximação de um campo magnético, as lâminas fecham-se, tocando uma na outra e fecham um circuito, havendo passagem de corrente. Assim é possível determinar os momentos em que a porta se encontra aberta ou fechada, de acordo com o estado do *reed switch*.

3.2.6 Estação meteorológica da FCUL

Para obter os dados da temperatura exterior e da humidade relativa exterior durante o processo de aquisição de dados, recorreu-se à estação meteorológica localizada no campus solar da FCUL (circunferência azul na Figura 23). A sala em estudo (circunferência verde na Figura 23) dista da estação meteorológica em cerca de 200m. A estação meteorológica é composta pelos sensores apresentados na Tabela 2 e por sensores para determinar a direção e velocidade do vento, irradiância global horizontal, irradiância difusa horizontal e irradiância direta normal. No entanto, os dados provenientes destes sensores não foram utilizados neste trabalho.

Tabela 2: Características da estação meteorológica da FCUL

Sensor	Medição	Especificações	
Lufft (<i>Weather Station 500</i>)	Temperatura	Amplitude de medição	-50 to 60 ° C
		Precisão	± 0,2°C (-20 to 50°C)
	Humidade Relativa	Amplitude de medição	0 to 100% RH
		Precisão	± 2% RH




Figura 23: Posição da estação meteorológica da FCUL em relação à sala em estudo

3.2.7 Base de dados climáticos exteriores

A estação meteorológica da FCUL não se encontra configurada para integração em projetos onde seja necessária leitura de dados de uma forma iterativa e constante. Para tal, não se adequa ao projeto em questão uma vez que na fase de atuação do sistema após construção dos modelos preditivos, a cada instante serão também necessários para além dos dados dos sensores do interior da sala, os dados climáticos exteriores. Assim, foi feita uma análise comparativa entre os dados da estação meteorológica da FCUL e das estações meteorológicas do *Weather Underground* (WU) nas proximidades da FCUL e concluiu-se que a estação apresentada na Figura 24, na Portela, a cerca de 4.4 km da FCUL, seria a escolhida para integrar o projeto visto que apresentava uma significativa coerência nos dados medidos em relação à estação da FCUL. Esta integração foi feita através do API disponibilizado gratuitamente pelo WU.



Figura 24: Posição da estação meteorológica do WU em relação à FCUL

3.3 Componentes de controlo do sistema de ventilação

De forma a melhorar a qualidade do ar interior, foi instalado entre a sala e o corredor adjacente um ventilador reversível axil *Helipac* da *France Air* e um motor que permite abrir e fechar uma janela basculante. Para atuar este sistema, foi instalado, no quadro elétrico que controla os referidos componentes, um *Arduino Uno* com uma *Shield* relé.

3.3.1 Ventilador reversível

O sistema mecânico de ventilação é composto por um ventilador tubular axial *Helipac* trifásico de 4 polos da *France Air* cujas características se apresentam na tabela que se segue [33].

Tabela 3: Características do ventilador tubular axial *Helipac* da *France Air*

Diâmetro (mm)	Tensão (V)	Frequência (Hz)	Potência Nominal (W)	Corrente Nominal (A)	dB (A)
300	400	50	102	0.33	68

Para diminuir o ruído de funcionamento do ventilador, foi instalado um atenuador acústico cilíndrico sem núcleo também comercializado pela *France Air*.



Figura 25: Ventilador e atenuador da *France Air* usados no projeto

Sendo este ventilador reversível, pode funcionar em dois sentidos, isto é: insuflar ou extrair ar da sala de aula. No momento de insuflação, o ar no corredor será forçado a entrar para a sala devido à diferença de pressão imposta pelo ventilador e o ar no interior da sala será expelido para o exterior através da abertura da janela. No momento de extração, o ar da sala será removido para o corredor uma vez mais devido à diferença de pressão imposta pelo ventilador e o ar exterior será forçado a entrar para a sala.

O caudal de insuflação e extração foi determinando com recurso a um medidor de velocidade *VelociCalc* da *TSI*. O valor obtido foi de aproximadamente 245 m³/h em ambos os modos de atuação do ventilador.

3.3.2 Janela basculante elétrica

Na janela basculante existente nesta sala foi instalado um motor com um braço que permite uma extensão de cerca de 20 cm, permitindo que se tenha aproximadamente uma área de 10% de janela aberta.

Esta janela é um elemento fundamental para todo o sistema pois permite a entrada de ar exterior e extração do ar interior com o auxílio do ventilador e permitirá também aplicar estratégias de ventilação natural.



Figura 26: Janela basculante elétrica

3.3.3 Componente de atuação do sistema

A *shield* de relé é uma componente do *Arduino* que permite controlar circuitos de alta tensão cujo *Arduino Uno* não tolera devido aos limites de tensão e corrente dos seus pinos digitais. Esta componente é montada sobre um *Arduino* e é composta por quatro relés de alta qualidade, fornecendo interfaces NO/NC (*Normally Opened* e *Normally Closed*).



Figura 27: Relay Shield usada neste projeto

Um relé consiste num interruptor electromagnético operado eletricamente. Através de um sinal elétrico de baixa potência este dispositivo permite abrir e fechar circuitos exteriores de maior corrente e tensão.

A Figura 28 mostra de uma forma simples o funcionamento de um relé.




Figura 28: Funcionamento de uma relay electromagnético

O relé tem como peças fundamentais a bobina, os contatos elétricos e a armadura. A Figura 28 corresponde a um momento em que não há corrente a circular na bobina, logo não há a geração de um campo magnético e o comum fica em contacto com o normalmente fechado (NC – *normally closed*). Este momento corresponde ao momento em que o circuito secundário estará aberto, portanto não terá corrente. Para fechar este segundo circuito, permitindo assim que um dispositivo a ele ligado entre em funcionamento, um sinal de baixa corrente é lançado no primeiro circuito, gera-se um campo elétrico na espira, dá-se um movimento rotacional da armadura e o comum entra em contacto com o normalmente aberto (NO – *normally opened*).

Será com base nestes princípios básicos de electromagnetismo que a janela e o ventilador reservisel serão atuados. Como já mencionado, a *shield* relé usada é composta por quatro relés, correspondendo a cada um a abertura da janela, o fecho e a atuação do ventilador nos dois sentidos.

3.3.4 Modos de atuação do Sistema e disposição dos sensores

Para este sistema, existem quatro possíveis modos de atuação.

- Configuração 0: Ventilador desligado e janela fechada.
- Configuração 1: Ventilador desligado e janela aberta (ventilação natural)
- Configuração 2: Ventilador ligado (insuflar no sentido corredor-sala) e janela aberta.
- Configuração 3: Ventilador ligado (extrair no sentido sala-corredor) e janela aberta.

A Figura 29 tem como intuito retratar as trocas de ar existentes dada a reversibilidade do ventilador. Na configuração 2, a vermelho, o ventilador é ligado de tal forma que o ar do corredor é forçado a entrar para a sala. Na configuração 3, a azul, o ar exterior é forçado a entrar para a sala pela janela basculante elétrica. Ainda na Figura 29 ilustra-se a disposição dos sensores no interior da sala. Estes sensores estão a cerca de 1.20m do chão, permitindo assim uma melhor caracterização da zona ocupada da sala.




Figura 29: Disposição dos sensores e configurações com o ventilador ligado

3.4 Arquitectura do sistema e protocolos de comunicação

Nesta sub-secção será abordada a arquitectura do sistema de monitorização da sala de aula e do sistema de atuação, as ligações entre os diferentes dispositivos usados e os protocolos de comunicação usados.

A figura que se segue ilustra a arquitetura dos sensores e dispositivos usados neste trabalho.

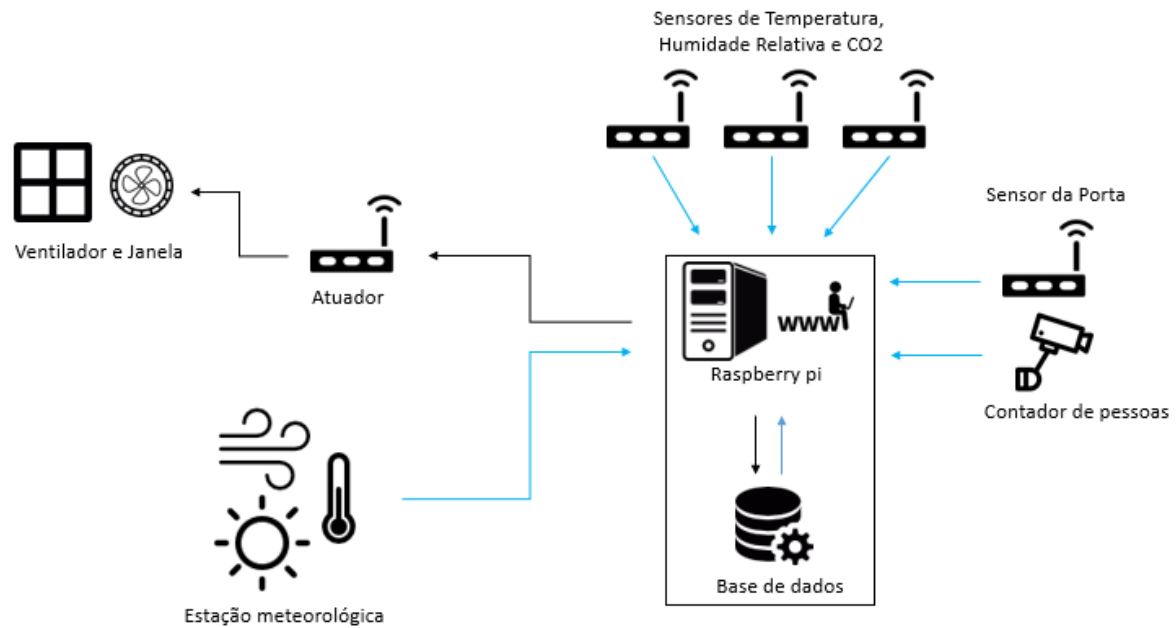


Figura 30: Arquitetura do sistema usado neste trabalho

3.4.1 Raspberry pi

Este dispositivo consiste num pequeno computador do tamanho de um cartão de crédito que funciona com um monitor de computador, teclado e rato. Devido ao seu baixo custo e funcionalidades, foi criado com o propósito de estimular o interesse pela computação para pessoas de todas as idades, permitindo aprender a programar em linguagens como *Scratch* e *Python*. O *Raspberry pi* tem a capacidade de fazer tudo aquilo que um computador portátil ou de secretária convencional faz, desde visualização de vídeos, processamento de texto, pesquisas na internet, entre outras [34]. O principal sistema operativo é o *Raspbian* e é baseado no *Debian GNU/Linux*) [35].



Figura 31: Raspberry pi 2 Modelo B

As características do *Raspberry pi* usado neste trabalho apresentam-se na tabela que se segue.

Tabela 4: Características do Raspberry pi 2 Modelo B

Processador	900 MHz quad-core ARM Cortex-A7 CPU
Memória RAM	1GB
Outras Características	4 portas USB
	40 pinos GPIO
	Porta Full HDMI
	Porta Ethernet
	Entrada Audio
	Cartão Micro SD
	VideoCore IV 3D graphics core

É no *Raspberry pi* que correm todos os códigos desenvolvidos em *python* para este trabalho. Foi desenvolvido um código para comunicação com os sensores de temperatura, humidade relativa, concentração de CO₂ e com o contador de pessoas; código para o controlo dos actuadores durante os momentos de treino da rede neuronal; código para o controlo dos actuadores após o treino da rede; código para monitorização do estado da porta e um código para se obterem os dados da estação meteorológica através do Weather Underground.

Para correr estes códigos, à excepção do código para monitorização do estado da porta, foi utilizado o *crontab*, uma funcionalidade dos sistemas operativos UNIX. Este comando permite calendarizar tarefas que serão executadas periodicamente pelo sistema operativo, permitindo assim uma correta sincronização entre todos os dispositivos, quer para obtenção de dados quer para atuar o sistema.

3.4.2 Comunicação entre os dispositivos usados

Como já foi mencionado anteriormente, os sensores de temperatura, humidade relativa e de concentração de CO₂ foram ligados a um *Arduino Uno* com uma *WiFi Shield*. Com este componente, criou-se um servidor web *HTTP* (*Hypertext Transfer Protocol*) em cada *Arduino*. A biblioteca da *WiFi Shield* permitirá, assim, que cada dispositivo responda a um pedido *HTTP* [30].

O *HTTP* é o protocolo usado para transmissão de dados pela World Wide Web desde 1990, e é cada vez mais usado para desenvolver aplicações complexas na rede à custa de pequenos serviços web (*web services*) [36].

O *HTTP* utiliza os protocolos de comunicação *TCP/IP* para transferência de dados nas redes de computadores. O *HTTP* especifica a forma como um cliente pede informação/dados a um servidor e a forma como este envia e responde a esse pedido de informação/dados [36].

No sistema montado na sala em estudo, o *Arduino* composto por sensores de temperatura, humidade relativa e de concentração de CO₂ corresponde a um servidor web enquanto o *Raspberry pi* se comporta como um cliente desses serviços. Este último, faz um pedido e o servidor web responde-lhe com os valores registados no momento do pedido. A comunicação entre os vários dispositivos é suportada por uma rede *WiFi* configurada num router ligado à rede da FCUL instalado na sala. Assim, este sistema funciona isoladamente numa rede local sem que outros elementos da rede da FCUL possam aceder à mesma, mas possibilitando que os elementos internos acessem ao exterior pela rede da FCUL.

Relativamente ao *People Counter*, está configurado de origem para funcionar como servidor web. Novamente, através do *HTTP*, é feito um pedido e este responde de volta os valores da ocupação para o instante em questão. A única diferença entre o *People Counter* e os sensores é que aqui a comunicação é feita com uma ligação cabo através da norma *IEEE 802.3af/802.3at*, permitindo que através do cabo *Ethernet* seja fornecida energia ao dispositivo e sejam transmitidos dados.

A comunicação entre o *Arduino* com sensor da porta e o *Raspberry pi* e a comunicação entre o atuador e o *Raspberry pi* foi feita através de uma comunicação serie com uma taxa de transmissão de 9600 bytes/s, sendo que os dispositivos estavam ligados através de um cabo *USB*.

3.4.3 Base de dados

Neste trabalho foi usada uma base de dados *SQLite3* [37] para armazenamento dos dados provenientes dos sensores e dos estados de atuação do sistema de ventilação. Esta base de dados foi instalada no *Raspberry pi* e uma das vantagens é que não precisa de estar configurada num servidor, facilitando a sua instalação e operações em projetos de menores dimensões.

A estrutura desta base de dados foi construída com o intuito de automatizar a possível adição de novos sensores ou a substituição de sensores existentes por avaria. Assim, foram criadas três tabelas. A primeira, serve para guardar as características dos sensores e a respetiva identificação. A segunda serve para confirmação das identidades dos sensores em uso para posterior inclusão dos dados na terceira tabela, que será usada para guardar todos os dados registados.

Abaixo apresentam-se as tabelas criadas na base de dados.

Tabela Sensores_Info					
ID (Primary Key)	Descrição	Data Início	Data Final	Medição	Unidades
1	Interior da sala	17-05-2016	?	Temperatura	°C
...

Tabela Operação		
ID_Operação	Descrição	ID_Sensor (Foreign Key)
1	Sensor1-Temp	1
...

Tabela Leituras		
ID_Sensor (Foreign Key)	TimeStamp	Valor
1	20/05/2016 16:48	22.5
...

Na tabela *Sensores_Info*, a coluna *ID* foi definida como *Primary Key*, significando isto que nela não se podem repetir entradas de igual valor. Na tabela *Operação*, a coluna *ID_Sensor* foi definida como *Foreign Key* referida ao *ID* da tabela *Sensores_Info*. Isto permite ligar duas tabelas através da *Primary Key* numa tabela diferente, sendo que o valor da *Foreign Key* tem de corresponder a um valor *Primary Key* na outra tabela.

Na Figura 32 mostra-se a relação entre os códigos e as tabelas na base de dados.




Figura 32: Relação entre as tabelas na base de dados

Quando é executado um código para obter dados dos sensores, esse código pede a identidade dos diferentes sensores em uso à tabela Operação (1). Esta tabela verifica se essa identidade existe na tabela Sensores_Info (2), grava os valores na tabela Leituras (3) e certifica-se que a identidade enviada está presente na tabela Sensores_Info (4).

O principal propósito desta relação entre as diferentes tabelas é a necessidade de vir a introduzir novos sensores no sistema ou trocar algum por avaria. Caso tal suceda, é apenas necessário introduzir a informação do novo sensor com a respetiva identidade na Tabela Sensores_Info e alterar o ID_Sensor na tabela Operação para a nova identidade daquele sensor. Assim, todos os códigos para obter dados dos sensores permanecem inalterados.

Capítulo 4 – Treino da rede neuronal

4.1 Aquisição de dados

A aquisição de dados para conhecimento das características da sala foi feita com recurso à atuação aleatória do ventilador e da janela dentro dos modos de operação permitidos por períodos de 15 minutos. Este procedimento foi feito durante 18 dias.

Antes de se proceder à identificação dos modelos, passou-se por uma fase de tratamento de dados. Nesta fase, todos os dados recolhidos foram sincronizados com os momentos de atuação do sistema. Trata-se então de um conjunto de dados discretos com intervalos de 15 minutos entre cada registo.

Nas figuras que se seguem mostra-se uma sequência de atuação aleatória do sistema de ventilação nos dias 21, 22 e 23 de junho. Os modos de atuação do sistema foram descritos anteriormente.

A cinzento, na base da figura, apresentam-se os estados de atuação do sistema, correspondendo a estes dados o eixo da direita. A preto, azul e laranja apresenta-se a temperatura exterior, interior e do corredor, respectivamente. Na sub-figura inferior, é apresentada a ocupação e o estado da porta.




Figura 33: Variação da temperatura interior na sala durante a aquisição de dados no dia 21, 22 e 23 de junho de 2016⁴

Na Figura 33 apresenta-se a variação da temperatura interior em resposta às atuações aleatórias do sistema, às perturbações internas e externas.

De igual forma, relativamente à concentração de CO₂, obtiveram-se as seguintes variações (Figura 34).

⁴ Fundo cinzento no subplot inferior indica que a porta estava aberta.




Figura 34: Variação da concentração de CO2 na sala durante a aquisição de dados no dia 21, 22 e 23 de junho de 2016

Nos anexos - A a este trabalho podem encontra-se mais gráficos relativos ao processo de aquisição de dados para o posterior treino dos modelos preditivos.

4.2 Definição dos modelos preditivos

Após o tratamento dos dados, procedeu-se à identificação dos modelos preditivos. Os dados foram separados em três grupos: treino, validação e simulação. As dimensões destes grupos são, respectivamente, 12, 4, 2 dias. Os dados de treino e validação são usados pelo algoritmo de treino para ajustar os parâmetros e para decidir ao fim de quantas iterações o processo de treino pára. Mais especificamente, o erro no conjunto de validação ao longo de todas as iterações é usado para escolher os parâmetros do modelo que correspondem à iteração onde esse erro é mínimo. O conjunto de simulação é usado para simular a variável modelada de forma a testar o desempenho e a correção do modelo com dados que este nunca viu no processo da sua identificação.

Os modelos preditivos dependem dos atrasos temporais relevantes das variáveis monitorizadas. Estas variáveis são dadas como entrada e através do algoritmo de LM, os parâmetros da rede são ajustados e é feito um ajuste aos valores de saída desejáveis. Esta estrutura no contexto de utilização de uma RBFNN corresponde ao modelo não-linear auto-rregressivo com entradas exógenas representado na figura abaixo.

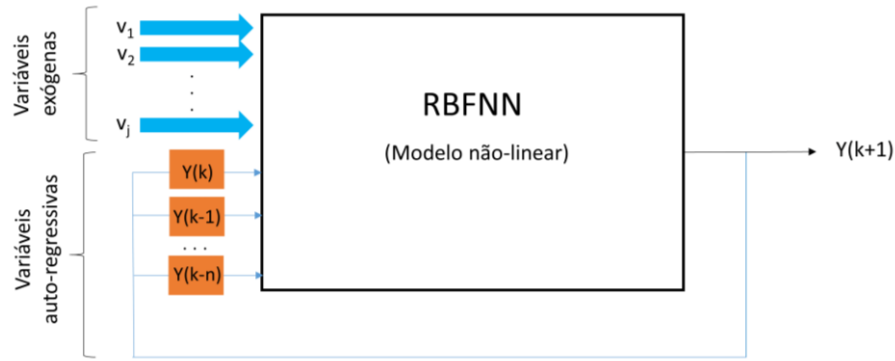


Figura 35: Estrutura não-linear da RBFNN

Na Figura 35, as setas de maior dimensão a azul representam as variáveis exógenas, enquanto as setas mais pequenas representam a estrutura de realimentação das variáveis auto-regressivas com atrasos no tempo. Esta figura tem como intuito apresentar a estrutura não-linear da RBFNN para o ajuste dos parâmetros no processo de treino.

A diversidade de modelos que podem ser criados é enorme uma vez que as variáveis de entrada podem variar, os atrasos temporais podem variar e o número de neurónios podem variar também. Para facilitar a escolha de todos estes elementos, procedeu-se a uma análise de correlação entre um conjunto de atrasos temporais das variáveis exógenas e a variável de saída para se perceber a relação temporal mais relevantes entre as variáveis testadas. Adicionalmente, tiveram-se em consideração os princípios físicos responsáveis pela variação da temperatura e da concentração de CO₂, que são as duas variáveis que se pretendem modelar. Tendo em consideração a análise e os princípios referidos, utilizou-se uma estratégia baseada na adição de variáveis e dos seus atrasos temporais de forma incremental, procedendo-se à análise dos erros de treinos, validação e simulação após cada alteração efetuada. O melhor modelo foi escolhido tendo em conta a menor distância à origem do erro de validação e do erro de simulação obtidos para um determinado modelo.

Para este trabalho considerou-se um horizonte de previsão (PH) de 2 horas, isto é, de 8 instantes. Isto significa que para obter o perfil previsto para os 8 instantes, o modelo é simulado realimentando a variável de saída nos instantes sucessivos. Durante a simulação, nos instantes futuros, utilizaram-se os valores medidos das variáveis exógenas. O erro de simulação corresponde à soma dos erros em cada instante. Nas Figura 36 e Figura 37, apresentam-se os erros de validação e simulação dos modelos treinados para a previsão da temperatura e da concentração de CO₂.




Figura 36: Erro de teste vs erro de simulação para os modelos testados para a temperatura interior




Figura 37: Erro de teste vs erro de simulação para os modelos testados para o CO₂ interior

Como já mencionado, a construção dos modelos preditivos com recurso à RBFNN depende de atrasos temporais das variáveis consideradas relevantes. Os gráficos acima são consequência de uma série de combinações possíveis entre as variáveis monitorizadas. No anexo - B, encontra-se disponível uma tabela para consulta das combinações testadas na procura do melhor modelo para a previsão da temperatura interior e para a concentração de CO₂.

A laranja, nas Figura 36 e Figura 37, encontram-se os modelos que melhor desempenho mostraram, tendo por isso sido os selecionados para incluir na estratégia de controlo preditivo baseado em modelos. Estes modelos foram compostos pelos seguintes atrasos temporais, como mostra a Tabela 5.

Tabela 5: Atrasos temporais usados para os modelos preditivos selecionados para temperatura interna (Tint) e para a concentração de CO₂ interior (CO₂int)

Variáveis	Atrasos temporais modelo Tint	Atrasos temporais modelo CO ₂ int
Temperatura interior	0,1,2,4,5	-
Temperatura corredor	0,1,2,4	-
Temperatura exterior	0,1,2,4	-
Janela	0,1,2,3	0,1,2,3
Ventilador	0,1,2,3	0,1,2,3
Ocupação	-	0,1
Humidade relativa exterior	-	-
Humidade relativa interior	-	-
Humidade relativa corredor	-	-
Porta	-	-
CO ₂ interior	-	0,1,2,3,5
CO ₂ corredor	-	0,1,2
Nº Neurónios	10	10

Dada a dependência dos modelos de variáveis exógenas, para uma correta previsão destas variáveis com um horizonte de previsão de 2 horas, foi necessário proceder-se à elaboração de modelos preditivos para a temperatura exterior, para a temperatura no corredor e para a concentração de CO₂ no corredor. Nestes casos, por simplificação, optou-se pelo desenvolvimento de modelos puramente auto-regressivos, isto é, modelos que dependam exclusivamente dos próprios atrasos temporais. Assim, testaram-se modelos considerando todos os atrasos temporais até 6, 12, 18 e 24 horas variando ainda do número de neurónios

entre 2 e 10. Os melhores modelos para cada variável bem como o número de neurónios foram escolhidos tendo em conta a menos distância à origem, como já explicado e apresentam-se na Tabela 6.

Tabela 6: Atrasos temporais das variáveis exógenas

Variáveis	Atrasos temporais modelo Text	Atrasos temporais modelo Tcorr	Atrasos temporais modelo CO2corr
Temperatura exterior	[0,23]	-	-
Temperatura corredor	-	[0,23]	-
CO2 corredor	-	-	[0,23]
Nº Neurónios	5	2	2

4.3 Previsão da ocupação

Para a previsão da ocupação, não se recorreu à rede neuronal. A ocupação foi dada a conhecer ao sistema estimando o número de ocupantes tendo em conta o horário de utilização da sala em estudo. Esta informação encontra-se disponível na Tabela 7.

Tabela 7: Previsão para a ocupação

Hora	Segunda	Terça	Quarta	Quinta	Sexta	Sábado	Domingo
00:00	0	0	0	0	0	0	0
01:00	0	0	0	0	0	0	0
02:00	0	0	0	0	0	0	0
03:00	0	0	0	0	0	0	0
04:00	0	0	0	0	0	0	0
05:00	0	0	0	0	0	0	0
06:00	0	0	0	0	0	0	0
07:00	0	0	0	0	0	0	0
08:00	15	15	15	15	15	0	0
09:00	15	15	15	15	15	0	0
10:00	15	15	15	15	15	0	0
11:00	15	15	15	15	15	0	0
12:00	15	15	15	15	15	0	0
13:00	15	15	15	15	15	0	0
14:00	5	5	5	5	5	0	0
15:00	5	5	5	5	5	0	0
16:00	5	5	5	5	5	0	0
17:00	5	5	5	5	5	0	0
18:00	5	5	5	5	5	0	0
19:00	5	5	5	5	5	0	0
20:00	5	5	5	5	5	0	0
21:00	0	0	0	0	0	0	0
22:00	0	0	0	0	0	0	0
23:00	0	0	0	0	0	0	0

Legenda:



Aulas do Departamento de Biologia

Utilização livre para os alunos do Departamento de Biologia

Capítulo 5 – Definição dos objetivos de controlo

Neste capítulo será abordada a estratégia utilizada para definir a função de custo. Como os principais requisitos deste trabalho se centram em otimizar um sistema de ventilação para maximização do conforto térmico e melhoria da qualidade do ar, a função de custo definida será baseada no modelo de conforto adaptativo e nas exigências de qualidade de ar, segundo o regulamento de desempenho energético dos edifícios de comércio e serviços (RECS).

5.1 Função de custo

A função de custo (J) foi definida tendo em conta as restrições para a temperatura de conforto segundo o modelo de conforto adaptativo e da qualidade do ar interior segundo a legislação portuguesa.


Para a temperatura de conforto, sabendo a temperatura média mensal exterior para introduzir na equação (5), definiu-se esta componente da função de custo (J^t) do seguinte modo:

- Para a temperatura de conforto e até -1.5°C da temperatura de conforto, $J^t(\text{Temp}) = 0$;
- Para temperaturas inferiores ou superiores à temperatura de conforto até aos limites de 80% de aceitabilidade, a função de custo tomará a forma de uma função quadrática, sendo que, à medida que os valores se aproximam dos limites de conforto, a penalização será maior;
- Para valores inferiores ou superiores aos limites de 80% de aceitabilidade, a função de custo tomará o valor máximo de 1.

Relativamente à qualidade do ar interior, esta componente da função de custo (J^c) foi definida do seguinte modo:

- Até se atingir os 1250 ppm, $J^c(\text{CO}_2) = 0$;
- Dos 1250 ppm até aos 1625 ppm, haverá uma evolução quadrática, sendo que, a partir do valor limite de 1625 ppm, a função de custo tomará o valor máximo, que será 1.

Graficamente, as funções de custo descritas tomam a seguinte forma⁵:



a)

⁵ Para gráfico da temperatura de conforto aqui apresentado foi definida uma temperatura média exterior de 23°C




Figura 38: Funções de custo para: a) temperatura interior e b) qualidade do ar interior

De seguida, foi definido que a temperatura interior teria um peso superior à qualidade do ar interior uma vez que, segundo [38], os ocupantes tendem a dar maior importância à temperatura de conforto do que à qualidade do ar. Assim, o valor final da função de custo será dado pela equação (15). Contudo, no caso de uma das componentes da função de custo já ser máximo, a função de custo total tomará o valor máximo de 1, independentemente do valor da outra componente. Estas restrições são apresentadas através do fluxograma na Figura 39.

$$J = \frac{2J^t(temp)}{3} + \frac{J^c(CO2)}{3} \quad (15)$$

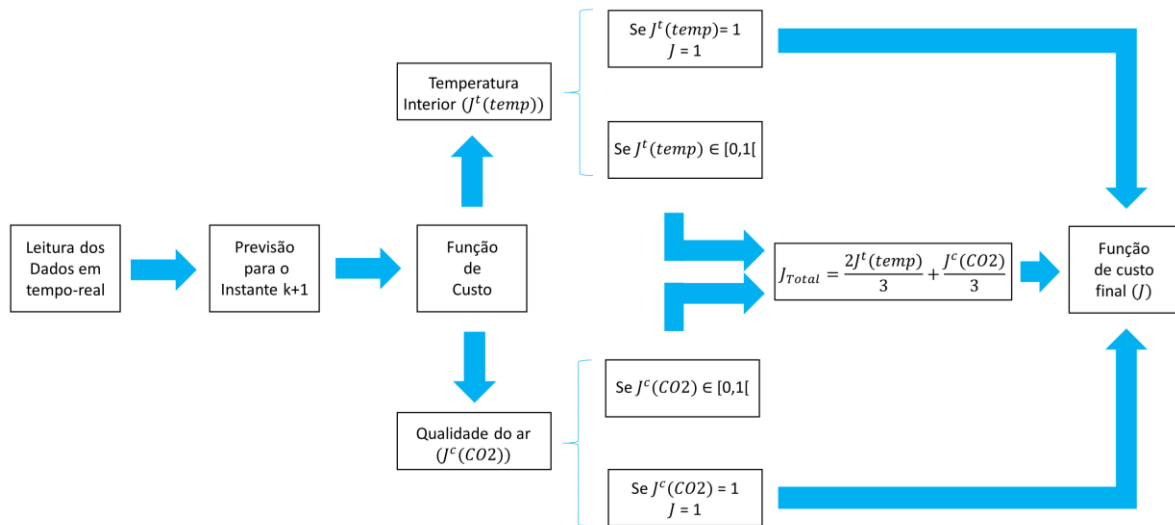


Figura 39: Fluxograma para definição do valor final da função de custo

5.2 Método de Branch and Bound

O método de *Branch and Bound* consiste numa técnica de procura estruturada usada para resolver problemas complexos de otimização discreta. Neste trabalho, a procura da melhor solução de atuação para um determinado instante consiste na procura pela sequência de ações que, para o horizonte de previsão definido, minimize a função de custo. Para tal, é usada uma estrutura em árvore onde o processo a otimizar é dividido em sub-problemas [19].

Para o instante atual, k , o método BB cria uma estrutura em árvore inicial para as ações que podem ser tomadas nesse instante de tempo. Para o instante $k+1$, é calculada a previsão da saída sendo esse valor avaliado através da função de custo, para cada ação. Para os próximos passos, o processo é repetido, sendo criados novos ramos em cada nó da estrutura em árvore a partir dos nós criados no passo anterior, utilizando para isso os modelos preditivos. O processo é continuamente repetido até se atingir o instante $k+PH$, onde o número total de ramos e de sequências de controlo igualam n^{PH} , sendo n o número de alternativas de controlo [19]. A solução ótima é então escolhida selecionando a sequência de controlo que, de $k+1$ até $k+PH$ minimize o custo acumulado, isto é:

$$J_{1:PH}(k) = \sum_{i=k+1}^{k+PH} J(i) \quad (16)$$

Contudo, como existem quatro possibilidades de atuação do sistema e a previsão é feita para duas horas, ou seja, 8 passos à frente ao instante atual, o número de soluções torna-se proibitivamente grande para uma rápida computação. Deste modo, são aplicadas algumas restrições que visam uma simplificação e mais rápida procura da melhor solução na estrutura em árvore.

As restrições impostas foram as seguintes [19]:

- Uso de limites para restringir ramificações
- Desenvolver uma procura mais detalhada até ao horizonte de controlo (CH), sendo $CH < PH$

Relativamente ao uso de limites para restringir as ramificações, foi definida a seguinte condição: caso o valor absoluto da diferença entre a temperatura interior e a temperatura de conforto seja superior a 3.5°C , então aquela sequência de ações de controlo é eliminada uma vez que o limite de 80% de aceitabilidade de conforto é excedido.

Para a segunda restrição imposta, a procura mais detalhada é feita até ao horizonte de controlo. O horizonte de controlo neste trabalho foi definido como sendo 1h, ou seja, 4 passos mais à frente em relação ao instante atual. A partir deste momento, para uma mais rápida computação e porque o erro acumulado não é significativo quando comparado com uma procura detalhada do primeiro ao último instante, a sequência de atuação é selecionada considerando a atuação com menor custo para cada instante. Isto significa então que, a partir do CH, a estrutura em árvore desenvolve apenas um ramo, que é a sequência com menor custo para cada instante.

As duas restrições descritas acima permitem eliminar uma vasta quantidade de possibilidades de atuação. Para otimizar a procura, tomou-se uma abordagem composta por 2 limites: um limite superior da função de custo total de $k+1$ até $k+PH$ e um limite inferior para o custo de $k+i$ até $k+PH$. A cada instante i , um ramo é seguido se o custo acumulado do instante 1 até $i-1$, $J_{1:i-1}(k)$ mais o custo do limite inferior de i até PH , $\hat{J}_{i:PH}(k)$ for inferior ao limite superior do custo total $\hat{J}_{1:PH}(k)$ [19]. Dado que o segundo termo traduz o uso de um perfil de controlo A_j no instante i , esta condição é traduzida pela seguinte equação [19]:

$$J_{1:i-1}(k) + J(k+1)|_{u(k+i-1)=A_j} + \hat{J}_{i+1:PH}(k) < \hat{J}_{1:PH}(k) \quad (17)$$

Antes de iniciar a otimização em cada instante k , uma primeira procura da melhor solução ao longo da árvore é efetuada escolhendo a ação de controlo que apresente menor custo para cada instante, $J(k+1)_{i=1}^{PH}$. O custo total é definido como o limite superior da função de custo total, $\hat{J}_{1:PH}(k)$. Se mais

tarde for encontrada uma sequência de ações de controlo com menor custo, este valor é substituído na variável descrita anteriormente. O limite inferior da função de custo total, é definido 0 para todos os passos da otimização [19].

Esta abordagem permite que a solução ótima seja sempre encontrado, de acordo a precisão dos modelos, permitindo assegurar o equilíbrio numa rápida computação na procura da melhor atuação para cumprir os requisitos de conforto e qualidade de ar interior ao longo do horizonte de previsão.

Capítulo 6 – Resultados experimentais

Definidos os modelos para previsão das variáveis de controlo e variáveis exógenas, definida a função de custo do sistema e definido o método de procura a melhor sequência de ações de controlo, colocou-se o sistema de ventilação em funcionamento com base nestes pressupostos.

As primeiras duas figuras, Figura 40 e Figura 41, representam o resultado da atuação do sistema de ventilação para os dias 12 e 13 de novembro de 2016. Para esta sequência de dois dias, a temperatura média mensal exterior foi de 16.6°C. Pela equação (5), a temperatura de conforto fixar-se-ia em 22.9°C, sendo que, para uma aceitabilidade de 80% dos ocupantes, os extremos dos valores de temperatura de conforto seriam 19.4°C e 26.4°C.




Figura 40: Variação da temperatura interior em função da atuação do sistema para o fim de semana de 12 e 13 de novembro

Visto tratar-se de um fim de semana, a ausência de ocupantes não permite criticar o sistema quanto à sua eficácia no arrefecimento da sala. No entanto, este gráfico permite analisar o esforço do sistema em evitar o arrefecimento noturno devido às baixas temperaturas verificadas no exterior. Este esforço é visível quando o sistema insufla a sala com ar vindo do corredor nos períodos noturnos (sensivelmente entre as 0h e as 8h) dado que a temperatura do corredor é relativamente próxima da temperatura do interior da sala, evitando, assim, o arrefecimento das superfícies no interior da sala. Nos períodos diurnos, devido à radiação solar e ao aumento da temperatura exterior, o sistema não toma qualquer atuação (janela fechada e ventilador desligado) e pela figura verifica-se que a temperatura interior se mantém constante e próxima do valor definido como conforto. Relativamente à previsão da temperatura interior, apesar de ter havido uma sobre-estimativa desta variável fase aos valores medidos, os valores previstos acompanham as subidas e descidas de temperatura verificadas, pelo que, pode-se afirmar que os modelos de previsão da temperatura interior apresentam bastante qualidade. A sobre-estimativa da temperatura deve-se ao facto do modelo de temperatura ter sido identificado com dados da temperatura

de junho e estar a ser utilizado com dados de temperatura significativamente mais baixo, sem ter sido atualizado para estas.

Na Figura 41 apresenta-se a variação da concentração de CO₂ para os dias mencionados.




Figura 41: Variação da concentração de CO₂ interior em função da atuação do sistema para o fim de semana de 12 e 13 de novembro

Relativamente à concentração de CO₂ no interior da sala, esta sequência de dois dias de fim de semana não revela a capacidade do sistema em reduzir a concentração de CO₂ no interior da sala pela inexistência de ocupantes. Para a previsão do CO₂, verifica-se que o modelo apresenta uma boa previsão apesar de algumas oscilações face aos valores medidos. Ainda assim, estas oscilações encontram-se próximas dos dados medidos.

Por fim, relativamente a esta sequência de dois dias de fim de semana, a Figura 42 traduz o custo acumulado para o horizonte de previsão em cada instante. O facto de a função de custo ser sempre próxima de 1 significa que o sistema conseguiu tomar ações que colocasse a temperatura interior e a concentração de CO₂ próximos dos valores de referência.




Figura 42: Função de custo para o fim de semana de 12 e 13 de novembro

Nas figuras que se seguem, Figura 43 e Figura 44, apresenta-se a variação da temperatura interior e da concentração do CO₂ em função dos estados de atuação do sistema de ventilação para os dias 15, 16 e 17 de novembro. Para esta sequência de três dias, a temperatura média mensal exterior baixou para 15.8°C, sendo que a temperatura de conforto baixou para 22.7°C, segundo a equação (5).




Figura 43: Variação da temperatura interior em função da atuação do sistema nos dias 15, 16 e 17 de novembro

Nesta figura, devido à existência de ocupantes, entre as 8h e as 13h verifica-se uma considerável subida da temperatura interior quando comparado com os dados registados no fim de semana. Nos períodos noturnos, uma vez mais, verifica-se a intenção do sistema em manter a temperatura interior o mais próxima possível da temperatura de conforto. Nos períodos em que a sala de aula está ocupada, pela atuação do sistema de ventilação, verificou-se uma temperatura máxima interior próxima dos 24°C, pelo que, apenas se superou a temperatura de conforto em 1.3°C. Uma vez mais, os valores previstos foram sobre-estimados mas acompanham as subidas e descidas das temperaturas medidas.

Para o mesmo período, a concentração de CO₂ no interior da sala variou conforme mostra a Figura 43.




Figura 44: Variação da concentração de CO₂ interior em função da atuação do sistema nos dias 15, 16 e 17 de novembro

Durante esta sequência de três dias de atuação do sistema de ventilação, o limiar de 1250 ppm apenas foi ultrapassado em dois instantes, no primeiro e no terceiro dia. A previsão da concentração de CO₂ acompanhou relativamente bem os valores medidos, permitindo assim uma eficiente atuação do ventilador e da janela para evitar que a concentração de CO₂ excedesse os limites de impostos ao sistema por longos períodos.

Para esta sequência de três dias com perturbações internas causadas pela existência de ocupação, verifica-se que o sistema apresenta custos acumulados superiores quando comparado com a sequência de dois dias no fim de semana, conforme mostra a Figura 45. Contudo, a função acumulada não atinge valores para além dos 2.5, sensivelmente. Isto significa que o sistema conseguiu prever sequências de ações que mantivesse os valores da temperatura e da concentração de CO₂ próximos dos valores de desejáveis, tendo tendência a baixa os valores da função de custo sempre que possível.




Figura 45: Função de custo para os dias 15, 16 e 17 de novembro

Para estas medições finais, não foram registados dados do estado da porta por avaria do sensor. Apesar do estado da porta não ter sido considerado relevante para a definição dos modelos de previsão da temperatura interior e da concentração do CO₂ interior, é claro que o facto da porta estar aberta ou não tem implicações na ventilação da sala, pelo que, os dados da concentração de CO₂ nesta sequência de três dias poderão ter sido influenciados pela abertura da porta por longos períodos.

Capítulo 7 – Conclusões

A aplicação de controlo preditivo baseado em modelos a sistemas de ventilação e climatização revelam-se ser uma importante metodologia de controlo destes sistemas com vista a aumentar as condições de conforto dos espaços interiores e a diminuir o consumo de energia usado nos edifícios.

Como pode ser analisado pelos dados registados no capítulo 6, as salas de aula, pela intensa utilização, necessitam constantemente de ar novo para manter níveis de qualidade do ar adequados às atividades desenvolvidas. No inverno a ventilação nos períodos diurnos permite também redução da temperatura interior para níveis próximos do conforto. Já no verão, ou dias mais quentes, a ventilação deve essencialmente ser feita em períodos noturnos para o arrefecimento do ar e paredes interiores, evitando o sobreaquecimento aquando da máxima temperatura exterior. Nos períodos diurnos, nos dias mais quentes, a ventilação dos espaços interiores geralmente apenas permite uma de duas possíveis escolhas: Ou opta-se por melhores temperaturas interiores, piorando a qualidade do ar ou opta-se por piorar a temperatura interior mas melhorar a qualidade do ar.

Os modelos preditivos desenvolvidos neste trabalho foram construídos com recurso a dados obtidos pela atuação aleatória do ventilador e da janela e por ocupação aleatória. Estes dados foram recolhidos em junho e julho e idealmente, estes modelos deveriam ser usados para dias semelhantes aos dias nos quais os modelos foram treinados. Contudo, devido às dificuldades que foram surgindo com o desenvolvimento deste trabalho, apenas foi possível colocar o sistema em funcionamento em meados de novembro, daí que a previsão da temperatura interior tenha algum erro face aos dados medidos pelos sensores. Por outro lado, quando se procedeu à aquisição de dados, em junho e em julho, uma vez que já não haviam aulas e são poucos os alunos que se encontram nas faculdades nestes meses, recolheram-se poucos dados com variações e quantidades pouco significativas de ocupação para uma posterior melhor caracterização aquando do treino dos modelos preditivos. Por fim, a arquitetura dos dispositivos usados tem uma boa margem de melhoramento para que, mais tarde, este sistema possa funcionar autonomamente.

Pelos resultados obtidos, tanto na fase de aquisição de dados como na fase final de atuação do sistema, pode-se concluir que o ventilador usado apresenta pouco caudal. Visto que a sala de aula tem cerca 230 m³ e o ventilador tem um caudal de cerca de 245m³/h, estamos perante um sistema que permite sensivelmente 1 renovação de ar por hora. Nos meses de inverno, devido às baixas temperaturas exteriores, poderá ser suficiente, mas no verão, com temperaturas exteriores elevadas e com os ganhos internos associados ao uso da sala, gera-se uma necessidade de responder mais rapidamente à subida da temperatura interior, sendo para isso necessário um caudal de insuflação superior, entre as 3 e 5 renovações de ar por hora.

Apesar dos problemas enumerados, este trabalho permitiu conhecer a potencialidade dos modelos baseados em redes neuronais para a previsão de determinadas variáveis aplicadas a edifícios e a integração destes modelos no controlo preditivo de sistemas de ventilação ou climatização. Para além da precisão, estes modelos são de rápida computação, mesmo quando implementados em pequenos dispositivos como um *Raspberry pi*, sendo esta uma grande vantagem quando comparado com modelos do *EnergyPlus*.

Referências

- [1] European Union, “Labelling and standard product information of the consumption of energy and other resources by energy-related products & Energy Performance of buildings,” *Off. J. Eur. Union*, vol. 53, p. 40, 2010.
- [2] Global Buildings Performance Network, “Building for our Future: The Deep Path for Closing the Emissions Gap in the Building Sector,” pp. 1–40, 2013.
- [3] Buildings Performance Institute Europe, *Europe ’s Buildings Under the Microscope: A country-by-country review of the energy performance of buildings*. 2011.
- [4] L. Pérez-Lombard, J. Ortiz, and C. Pout, “A review on buildings energy consumption information,” *Energy and Buildings*, vol. 40, no. 3, pp. 394–398, 2008.
- [5] H. B. Awbi, *Ventilation of Buildings*, 2003.
- [6] J. M. Daisey, W. J. Angell, and M. G. Apte, “Indoor air quality, ventilation and health symptoms in schools: an analysis of existing information,” *Indoor Air*, vol. 13, no. 1, pp. 53–64, 2003.
- [7] J. Sinopoli, *Smart Building Systems for Architects, Owners and Builders*, 2010.
- [8] S. Haykin, *Neural Networks and Learning Machines*, 2009.
- [9] Incropera, Frank P; Bergman, Theodore L; Lavine, Adrienne S; DeWitt, David P; *Fundamentals of Heat and Mass Transfer*, John Wiley & Sons, 2011.
- [10] G. Carrilho da Graça and P. Linden, “Ten questions about natural ventilation of non-domestic buildings,” *Build. Environ.*, vol. 107, pp. 263–273, 2016.
- [11] U. C. Berkeley, G. S. Brager, R. De Dear, and R. De Dear, “Climate , Comfort & Natural Ventilation : A new adaptive comfort standard for ASHRAE Standard 55,” *Cent. Built Environmen*, 2001.
- [12] Portaria n. 353-A/2013, “Regulamento de Desempenho Energético dos Edifícios de Comércio e Serviços (RECS) - Requisitos de Ventilação e Qualidade do Ar Interior,” *Diário da República*, 2013.
- [13] E. F. Camacho and C. Bordons, *Model predictive control*. 2007.
- [14] A. Afram and F. Janabi-Sharifi, “Theory and applications of HVAC control systems - A review of model predictive control (MPC),” *Build. Environ.*, vol. 72, pp. 343–355, 2014.
- [15] M. Killian and M. Kozek, “Ten questions concerning model predictive control for energy efficient buildings,” *Build. Environ.*, 2016.
- [16] X. Li and J. Wen, “Review of building energy modeling for control and operation,” *Renew. Sustain. Energy Rev.*, vol. 37, pp. 517–537, 2014.
- [17] P. May-Ostendorp, G. P. Henze, C. D. Corbin, B. Rajagopalan, and C. Felsmann, “Model-predictive control of mixed-mode buildings with rule extraction,” *Build. Environ.*, vol. 46, no. 2, pp. 428–437, 2011.

- [18] N. M. Mateus, A. Pinto, and G. C. Da Graça, "Validation of EnergyPlus thermal simulation of a double skin naturally and mechanically ventilated test cell," *Energy Build.*, vol. 75, no. JUNE, pp. 511–522, 2014.
- [19] P. M. Ferreira, A. E. Ruano, S. Silva, and E. Z. E. Conceição, "Neural networks based predictive control for thermal comfort and energy savings in public buildings," *Energy Build.*, vol. 55, pp. 238–251, 2012.
- [20] R. Mena, F. Rodríguez, M. Castilla, and M. R. Arahál, "A prediction model based on neural networks for the energy consumption of a bioclimatic building," *Energy Build.*, vol. 82, pp. 142–155, 2014.
- [21] T. Kazanasmaz, M. Günaydin, and S. Binol, "Artificial neural networks to predict daylight illuminance in office buildings," *Build. Environ.*, vol. 44, no. 8, pp. 1751–1757, 2009.
- [22] J. Braun and N. Chaturvedi, "An Inverse Gray-Box Model for Transient Building Load Prediction," *HVAC&R Res.*, vol. 8, no. 1, pp. 73–99, 2002.
- [23] P. M. Ferreira, E. a. Faria, and A. E. Ruano, "Neural network models in greenhouse air temperature prediction," *Neurocomputing*, vol. 43, 2002.
- [24] K. Levenberg, A method for the solution of certain non-linear problems in least squares, *The Quarterly of Applied Mathematics* (2) (1944) 164–168
- [25] D.W. Marquardt, An algorithm for least-squares estimation of nonlinear parameters, *Journal of the Society for Industrial and Applied Mathematics* 11 (2) (1963) 431–441
- [26] P. M. Ferreira and A. E. Ruano, "Exploiting the separability of linear and nonlinear parameters in radial basis function networks," *Proceedings of the IEEE 2000 Adaptive Systems for Signal Processing, Communications, and Control Symposium*, Lake Louise, Alta., 2000, pp. 321–326.
- [27] P.M. Ferreira, E. Faria, A.E. Ruano, Neural network models in greenhouse air temperature prediction, *Neurocomputing* 43 (1–4) (2002) 51–75
- [28] A.E. Ruano, P.M. Ferreira, C. Fonseca, An overview of non-linear identification and control with neural networks, in: A.E. Ruano (Ed.), *Intelligent Control Using Soft-Computing Methodologies*, vol. 70 of *Control Series*, IEE Publishing, 2005, pp. 37–87
- [29] P.M. Ferreira, A.E. Ruano, Evolutionary multiobjective neural network models identification: evolving task-optimised models, in: *New Advances in Intelligent Signal Processing*, vol. 372/2011 of *Studies in Computational Intelligence*, Springer, 2011, pp. 21–53
- [30] Arduino [Online]. Available: <https://www.arduino.cc/>. Accessed: 31-Aug-2016
- [31] SHT15 Sensirion [Online]. Available: <https://www.sensirion.com/products/humidity-sensors/digital-humidity-sensors-for-accurate-measurements/>. Accessed: 31-Aug-2016
- [32] CO2 Meter [Online]. Available: <http://www.co2meter.com/products/k-30-co2-sensor-module>. Accessed: 31-Aug-2016
- [33] France Air [Online]. Available: http://www.france-air.com/Portals/0/fichier/documentation/PC/PC_2398_15.pdf. Accessed: 31-Aug-2016
- [34] Raspberry pi [Online]. Available: <https://www.raspberrypi.org/>. Accessed: 05-Sep-2016

[35] Debian GNU/Linux [Online] Available: <https://www.debian.org/index.pt.html>

[36] Javvin Technologies, Network Protocols Handbook, 2005

[37] SQLite3 [Online] Available: <https://sqlite.org/>

[38] M. Frontczak and P. Wargocki, “Literature survey on how different factors influence human comfort in indoor environments,” *Build. Environ.*, vol. 46, no. 4, pp. 922–937, 2011

Anexo – A




Figura 46: Variação da temperatura interior na sala durante a aquisição de dados no dia 23 e 24 de junho de 2016




Figura 47: Variação da concentração de CO2 na sala durante a aquisição de dados no dia 23 e 24 de junho de 2016




Figura 48: Variação da temperatura interior na sala durante a aquisição de dados no dia 27 e 28 de junho de 2016




Figura 49: Variação da concentração de CO2 na sala durante a aquisição de dados no dia 27 e 28 de junho de 2016




Figura 50: Variação da temperatura interior na sala durante a aquisição de dados no dia 29 e 30 de junho de 2016




Figura 51: Variação da concentração de CO2 na sala durante a aquisição de dados no dia 29 e 30 de junho de 2016

Anexo – B

- Modelos de previsão para a temperatura interior

Tabela 8: Modelos de previsão para a temperatura interior – teste 1 a 19

Inputs (Tai)	Teste 1	Teste 2	Teste 3	Teste 4	Teste 5	Teste 6	Teste 7	Teste 8	Teste 9	Teste 10	Teste 11	Teste 12	Teste 13	Teste 14	Teste 15	Teste 16	Teste 17	Teste 18	Teste 19
Temperatura interior	0,1,3	0,1,3,5,7	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,4,5	0,1,2,4,5	0,1,2,4,5
Temperatura exterior	0	0,2	0,2	0,1,3	0,1,3	0,1,3,5	0,1,3,5	0,1,3,5	0,1,3	0,1,3	0,1,3	0,1,3,4	0,1,3,4	0,1,3,4	0,1,3,5	0,1,3,5	0,1,3,5	0,1,2,4	0,1,2,4
Temperatura corredor	0	0,2	0,2	0,2	0,2	0,2,5	0,2,5	0,2,5	0,2	0,2	0,2	0,2,4	0,2,4	0,2,4	0,1,2,4	0,1,3,4	0,1,2,4	0,1,2,4	0,1,2,4
Janela	0,1	0,1	0,1,2	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,3,5
Ventilador	0,1,3	0,1,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,4,5
Ocupação	0,1	0,1	0,1	-	-	-	0,1	0,1	-	-	-	-	-	-	-	0	0,1	-	-
HR exterior	-	-	-	-	-	-	-	0,2	-	-	-	-	-	-	-	-	-	-	-
HR interior	-	-	-	-	-	-	0,1	0,1,2	-	-	-	-	-	-	-	-	0,2	-	-
Porta	-	-	-	-	-	-	-	-	-	-	-	-	1,2	0,1,2	-	-	-	-	-
HR corredor	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
CO2 interior	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0,1	0,1	-	-
CO2 corredor	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Iterações	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60
Neurónios	12	12	12	12	10	12	12	12	5	8	14	10	10	10	10	10	10	10	10
Erro Treino*MV	0.163	0.155	0.142	0.152	0.152	0.143	0.14	0.127	0.159	0.16	0.137	0.146	0.14	0.139	0.138	0.138	0.135	0.145	0.144
Erro Teste*MV	0.212	0.155	0.184	0.166	0.167	0.153	0.177	0.178	0.202	0.15	0.212	0.159	0.18	0.183	0.196	0.148	0.169	0.178	0.197
Erro Simulação*MV	1.683	1.558	1.433	1.429	1.373	1.391	1.468	1.423	1.458	1.431	1.437	1.366	1.393	1.427	1.373	1.371	1.395	1.356	1.398
Erro Simulação/PH	0.210	0.195	0.179	0.179	0.172	0.174	0.184	0.178	0.182	0.179	0.180	0.171	0.174	0.178	0.172	0.171	0.174	0.170	0.175
Distância Origem	1.696	1.566	1.445	1.439	1.383	1.399	1.479	1.434	1.472	1.439	1.453	1.375	1.405	1.439	1.387	1.379	1.405	1.368	1.412

NOTAS:

- MV significa valor máximo. O treino da rede neuronal é feito com uma normalização dos dados entre 0 e 1.
- Os números na tabela referentes a cada variável indicam o atraso ou atrasos temporais considerados para a construção do modelo preditivo

Tabela 9: Modelos de previsão para a temperatura interior – teste 20 a 38

Inputs (Tai)	Teste 20	Teste 21	Teste 22	Teste 23	Teste 24	Teste 25	Teste 26	Teste 27	Teste 28	Teste 29	Teste 30	Teste 31	Teste 32	Teste 33	Teste 34	Teste 35	Teste 36	Teste 37	Teste 38
Temperatura interior	0,1,2,4,5	0,1,2,4,5	0,1,2,4,5	0,1,2,4,5	0,1,2,4,5	0,1,2,4,5	0,1,2,4,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,4	0,1,2,3,4	0,1,2,3,5	0,1,2,3,5	0,1,2,4,5,7
Temperatura exterior	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,3,4	0,1,3,4	0,1,3,4	0,1,3,4	0,1,3,4	0,1,3,4	0,1,3,4	0,1,2,4	0,1,2,4	0,1,3,4	0,1,3,4	0,1,3,4,5
Temperatura corredor	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,2,4	0,2,4	0,2,4	0,2,4	0,2,4	0,2,4	0,2,4	0,1,3,4	0,1,3,4	0,2,4	0,2,4	0,1,2,4
Janela	0,1,3,5	0,1,3,5	0,1,3,5	0,1,3,5	0,1,3,5	0,1,3,5	0,1,3,5	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3,5	0,1,2,3,5	0,1,2,3	0,1,2,3	0,1,2,3,5
Ventilador	0,1,2,4,5	0,1,2,4,5	0,1,2,4,5	0,1,2,4,5	0,1,2,4,5	0,1,2,4,5	0,1,2,4,5	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3,5	0,1,2,3,5	0,1,2,3	0,1,2,3	0,1,2,3,5
Ocupação	-	-	-	-	-	-	0,1,3	-	-	-	-	-	-	-	-	-	0,1	-	-
HR exterior	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
HR interior	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	1,3	0,1,3	-
Porta	-	-	-	-	-	-	1,3	-	-	-	-	-	-	-	-	-	0	-	-
HR corredor	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
CO2 interior	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
CO2 corredor	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Iterações	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60
Neurónios	5	6	7	8	9	12	10	5	6	7	8	9	11	12	8	10	10	10	10
Erro Treino*MV	0.178	0.165	0.161	0.153	0.147	0.151	0.135	0.17	0.159	0.157	0.154	0.15	0.142	0.144	0.149	0.149	0.131	0.144	0.147
Erro Teste*MV	0.207	0.182	0.21	0.197	0.187	0.178	0.167	0.204	0.177	0.178	0.157	0.176	0.175	0.175	0.185	0.165	0.177	0.166	0.171
Erro Simulação*MV	1.491	1.477	1.425	1.41	1.472	1.424	1.377	1.566	1.413	1.438	1.383	1.372	1.381	1.364	1.421	1.533	1.397	1.375	1.438
Erro Simulação/PH	0.186	0.185	0.178	0.176	0.184	0.178	0.172	0.196	0.177	0.180	0.173	0.172	0.173	0.171	0.178	0.192	0.175	0.172	0.180
Distância Origem	1.505	1.488	1.440	1.424	1.484	1.435	1.387	1.579	1.424	1.449	1.392	1.383	1.392	1.375	1.433	1.542	1.408	1.385	1.448

Tabela 10: Modelos de previsão para a temperatura interior – teste 39 a 50

Inputs (Tai)	Teste 39	Teste 40	Teste 41	Teste 42	Teste 43	Teste 44	Teste 45	Teste 46	Teste 47	Teste 48	Teste 49	Teste 50
Temperatura interior	0,1,2,3,5	0,1,2,4,5	0,1,2,4,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,4,5	0,1,2,4,5
Temperatura exterior	0,1,2,3,5	0,1,2,4	0,1,2,4	0,1,3	0,1,3	0,1,3	0,1,3	0,1,3,4	0,1,3,4	0,1,3,4	0,1,2,4	0,1,2,4
Temperatura corredor	0,1,2,3	0,1,2,4	0,1,2,4	0,2	0,2	0,2	0,2	0,2,4	0,2,4	0,2,4	0,1,2,4	0,1,2,4
Janela	0,1,2,3,4	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3
Ventilador	0,1,2,3,4	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3
Ocupação	-	0,1	-	-	-	-	-	0,1	-	-	-	0,1
HR exterior	-	-	0,1	-	-	-	-	-	-	1,4	-	-
HR interior	-	1,3	0,1	-	-	-	-	-	1,3	1,3	1,3	1,3
Porta	-	-	-	-	-	-	-	0	-	-	-	0
HR corredor	-	-	0	-	-	-	-	-	-	-	-	-
CO2 interior	-	-	-	-	-	-	-	-	-	-	-	-
CO2 corredor	-	-	-	-	-	-	-	-	-	-	-	-
Iterações	60	60	60	60	60	60	60	60	60	60	60	60
Neurónios	10	10	10	8	7	11	14	10	10	10	10	10
Erro Treino*MV	0.145	0.153	0.135	0.159	0.157	0.147	0.15	0.14	0.146	0.138	0.151	0.143
Erro Teste*MV	0.166	0.17	0.179	0.175	0.168	0.205	0.171	0.17	0.168	0.176	0.16	0.147
Erro Simulação*MV	1.423	1.387	1.421	1.44	1.392	1.503	1.429	1.418	1.395	1.623	1.371	1.396
Erro Simulação/PH	0.178	0.173	0.178	0.180	0.174	0.188	0.179	0.177	0.174	0.203	0.171	0.175
Distância Origem	1.433	1.397	1.432	1.451	1.402	1.517	1.439	1.428	1.405	1.633	1.380	1.404

- Modelos de previsão para o CO₂ interior

Tabela 11: Modelos de previsão para a concentração do CO₂ interior – teste 51 a 69

Inputs (co2)	Teste 51	Teste 52	Teste 53	Teste 54	Teste 55	Teste 56	Teste 57	Teste 58	Teste 59	Teste 60	Teste 61	Teste 62	Teste 63	Teste 64	Teste 65	Teste 66	Teste 67	Teste 68	Teste 69
CO2 interior	0,1,2,4	0,1,2,3	0,1,2,3	0,1,2,3, 4	0,1,2,3, 4	0,1,2,3	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 4	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5
CO2 corredor	0,1,3	0,1,2	0,1,2	0,1,2,4	0,1,2,4	0,1,2	0,1,2	0,1,2	0,1,2	0,1,2	0,1,2,4	0,1,2,4	0,1,2,3	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,3	0,1,2,4
Ocupação	0,1	0,1,2	,	0	0,1	0	,	0	0,1	0,1,3	,	,	,	,	,	0	0,1	,	,
Janela	0,1,2,3	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,4	0,1,2,3, 5	0,1,2,3, 4	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3	0,1,2,3, 5
Ventilador	0,1,2,3	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,4	0,1,2,3, 5	0,1,2,3, 4	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3	0,1,2,3, 5
Porta	-	-	-	-	0,1	-	-	0	-	-	-	-	-	-	-	-	-	-	-
Temperatura interior	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0,1	0,1	1,3	-	-
Temperatura exterior	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
HR exterior	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
HR interior	-	-	-	0	0	0,1	-	-	-	-	-	-	-	0,1	-	-	-	-	-
HR corredor	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Temperatura corredor	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Iterações	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60
Neurónios	10	10	10	10	10	10	10	10	10	10	10	10	10	10	10	10	10	10	12
Erro Treino*MV	13.162	13.294	14.216	13.147	11.277	12.974	12.888	11.542	11.4	12.801	11.91	12.122	12.849	11.778	12.171	12.021	13.231	14.091	13.556
Erro Teste*MV	13.263	15.661	14.566	14.794	13.807	15.589	15.048	15.954	15.292	12.651	16.705	20.332	19.276	19.543	15.337	14.193	11.499	14.235	15.401
Erro Simulação*MV	56.499	59.596	58.036	54.027	52.834	57.062	61.595	54.589	48.717	50.711	57.866	60.051	60.89	64.738	63.747	51.731	55.113	62.411	61.811
Erro Simulação/PH	7.062	7.450	7.255	6.753	6.604	7.133	7.699	6.824	6.090	6.339	7.233	7.506	7.611	8.092	7.968	6.466	6.889	7.801	7.726
Distancia Origem	58.035	61.619	59.836	56.016	54.608	59.153	63.407	56.873	51.061	52.265	60.229	63.400	63.868	67.623	65.566	53.643	56.300	64.014	63.701

Tabela 12: Modelos de previsão para a concentração do CO₂ interior – teste 70 a 88

Inputs (co2)	Teste 70	Teste 71	Teste 72	Teste 73	Teste 74	Teste 75	Teste 76	Teste 77	Teste 78	Teste 79	Teste 80	Teste 81	Teste 82	Teste 83	Teste 84	Teste 85	Teste 86	Teste 87	Teste 88
CO2 interior	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5
CO2 corredor	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2	0,1,2	0,1,2	0,1,2	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2	0,1,2	0,1,2,4	0,1,2,4	0,1,2,4
Ocupação	,	,	,	,	0,1	0,1	0,1	0,1	0,1,2	0,1,2	0,1,2	0,1,2	0,1,2	0,1,2	0	0,1	0,1	-	-
Janela	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3	0,1,2,3,5	0,1,3,5	0,1,3,5	0,1,2,4
Ventilador	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,4
Porta	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Temperatura interior	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Temperatura exterior	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
HR exterior	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
HR interior	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
HR corredor	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Temperatura corredor	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Iterações	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60
Neurónios	5	7	8	9	5	6	8	12	5	7	8	9	11	12	10	10	10	10	5
Erro Treino*MV	13.855	12.477	13.356	13.543	11.061	13.369	12.835	14.913	12.77	13.195	12.217	12.826	11.659	14.036	12.02	11.939	11.676	11.921	13.712
Erro Teste*MV	13.781	19.11	14.403	17.358	19.795	14.138	11.374	13.86	14.738	14.389	13.642	14.007	15.634	15.549	15.531	16.914	12.324	19.568	15.742
Erro Simulação*MV	65.463	66.522	58.934	55.727	50.048	53.085	53.315	56.815	53.582	54.83	54.117	52.59	54.225	56.46	53.258	54	55.133	62.533	55.411
Erro Simulação/PH	8.183	8.315	7.367	6.966	6.256	6.636	6.664	7.102	6.698	6.854	6.765	6.574	6.778	7.058	6.657	6.750	6.892	7.817	6.926
Distancia Origem	66.898	69.212	60.668	58.368	53.820	54.935	54.515	58.481	55.572	56.687	55.810	54.423	56.434	58.562	55.476	56.587	56.494	65.523	57.604

Tabela 13: Modelos de previsão para a concentração do CO₂ interior – teste 89 a 107

Inputs (co2)	Teste 89	Teste 90	Teste 91	Teste 92	Teste 93	Teste 94	Teste 95	Teste 96	Teste 97	Teste 98	Teste 99	Teste 100	Teste 101	Teste 102	Teste 103	Teste 104	Teste 105	Teste 106	Teste 107
CO2 interior	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 4	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3, 5
CO2 corredor	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,3, 4	0,1,3	0,1,3	0,1,3	0,1,3,5	0,1,3,5	0,1,3	0,1,3	0,1,3	0,1,3	0,1,3	0,1,3
Ocupação	-	-	-	-	-	-	-	-	0	-	0,1	0	-	0,1	0,1	0,1	0,1	0,1	0,1
Janela	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,3, 4	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3
Ventilador	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,4	0,1,2,3, 4	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3, 5	0,1,2,3, 5	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,2,3
Porta	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Temperatura interior	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Temperatura exterior	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
HR exterior	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
HR interior	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
HR corredor	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Temperatura corredor	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Iterações	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60
Neurónios	6	7	8	9	11	12	14	10	10	10	10	10	10	5	6	7	8	9	12
Erro Treino*MV	14.873	13.588	15.723	14.443	13.22	12.677	12.968	12.39	10.5	11.968	12.241	13.798	14.13	12.031	12.095	12.349	14.596	14.805	11.125
Erro Teste*MV	15.542	15.202	14.77	12.019	17.503	13.438	15.459	22.529	17.747	19.424	15.101	15.593	15.189	18.283	18.12	16.002	15.137	15.067	15.249
Erro Simulação*MV	57.026	53.165	52.399	54.949	56.622	55.219	57.826	53.572	49.281	56.536	50.415	56.862	60.315	56.352	49.557	52.67	52.725	56.364	51.31
Erro Simulação/PH	7.128	6.646	6.550	6.869	7.078	6.902	7.228	6.697	6.160	7.067	6.302	7.108	7.539	7.044	6.195	6.584	6.591	7.046	6.414
Distancia Origem	59.106	55.296	54.441	56.248	59.266	56.831	59.857	58.116	52.379	59.780	52.628	58.961	62.198	59.244	52.766	55.047	54.855	58.343	53.528

Tabela 14: Modelos de previsão para a concentração do CO₂ interior – teste 108 a 117

Inputs (co2)	Teste 108	Teste 109	Teste 110	Teste 111	Teste 112	Teste 113	Teste 114	Teste 115	Teste 116	Teste 117
CO2 interior	0,1,2,3,5	0,1,2,3,4	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5
CO2 corredor	0,1,3	0,1,2,3	0,1,2,3	0,1,2,3	0,1,3	0,1,3	0,1,3	0,1,3	0,1,3	0,1,3
Ocupação	0,1	-	-	0	0,1,3	0,1,3	0,1,3	0,1,3	0,1,3	0,1,3
Janela	0,1,2,3	0,1,2,3,5	0,1,2,3	0,1,2,3	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5
Ventilador	0,1,2,3	0,1,2,3,5	0,1,2,3	0,1,2,3	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5	0,1,2,3,5
Porta	-	-	-	-	-	-	-	-	-	-
Temperatura interior	-	-	0,1,2	0,1,2	-	-	-	-	-	-
Temperatura exterior	-	-	-	-	-	-	-	-	-	-
HR exterior	-	-	-	-	-	-	-	-	-	-
HR interior	-	1,3	-	-	-	-	-	-	-	-
HR corredor	-	1,3	-	-	-	-	-	-	-	-
Temperatura corredor	-	-	-	-	-	-	-	-	-	-
Iterações	60	60	60	60	60	60	60	60	60	60
Neurónios	14	10	10	10	10	5	6	7	8	12
Erro Treino*MV	12.677	13.132	15.361	14.635	11.776	12.487	12.314	11.849	12.542	11.439
Erro Teste*MV	14.489	11.386	17.26	16.354	13.554	10.712	12.164	15.007	13.268	15.961
Erro Simulação*MV	51.832	64.737	54.419	53.529	52.38	57.656	51.473	51.407	53.209	51.589
Erro Simulação/PH	6.479	8.092	6.802	6.691	6.548	7.207	6.434	6.426	6.651	6.449
Distancia Origem	53.819	65.731	57.091	55.971	54.105	58.643	52.891	53.553	54.838	54.002

- Modelo de previsão para a temperatura exterior

Tabela 15: Modelos de previsão para a temperatura exterior – teste 1 a 19

Inputs (Text)	Teste 1	Teste 2	Teste 3	Teste 4	Teste 5	Teste 6	Teste 7	Teste 8	Teste 9	Teste 10	Teste 11	Teste 12	Teste 13	Teste 14	Teste 15	Teste 16	Teste 17	Teste 18	Teste 19
Temperatura exterior	0,...,23	0,...,23	0,...,23	0,...,23	0,...,23	0,...,23	0,...,23	0,...,23	0,...,23	0,...,47	0,...,47	0,...,47	0,...,47	0,...,47	0,...,47	0,...,47	0,...,47	0,...,47	0,...,71
Iterações	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60
Neurónios	2	3	4	5	6	7	8	9	10	2	3	4	5	6	7	8	9	10	2
Erro Teste*MV	0.347	0.333	0.327	0.311	0.317	0.317	0.315	0.315	0.299	0.384	0.313	0.313	0.299	0.288	0.297	0.297	0.276	0.284	0.343
Erro Treino*MV	0.424	0.325	0.324	0.416	0.33	0.36	0.37	0.343	0.401	0.41	0.342	0.37	0.317	0.358	0.351	0.344	0.357	0.315	0.418
Erro Simulação*MV	7.33	4.42	4.289	4.262	4.466	4.451	4.501	4.833	4.38	15.881	6.367	6.078	6.579	6.642	5.941	6.072	6.809	6.09	10.406
Erro Simulação/PH	0.916	0.553	0.536	0.533	0.558	0.556	0.563	0.604	0.548	1.985	0.796	0.760	0.822	0.830	0.743	0.759	0.851	0.761	1.301
Distancia Origem	7.342	4.432	4.301	4.282	4.478	4.466	4.516	4.845	4.398	15.886	6.376	6.089	6.587	6.652	5.951	6.082	6.818	6.098	10.414

Tabela 16: Modelos de previsão para a temperatura exterior – teste 20 a 34

Inputs (Text)	Teste 20	Teste 21	Teste 22	Teste 23	Teste 24	Teste 25	Teste 26	Teste 27	Teste 28	Teste 29	Teste 30	Teste 31	Teste 32	Teste 33	Teste 34
Temperatura exterior	0,...,71	0,...,71	0,...,71	0,...,71	0,...,71	0,...,71	0,...,71	0,...,71	0,...,71	0,...,95	0,...,95	0,...,95	0,...,95	0,...,95	0,...,95
Iterações	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60
Neurónios	3	4	5	6	7	8	9	10	2	3	4	5	6	7	8
Erro Teste*MV	0.3	0.298	0.287	0.272	0.295	0.28	0.258	0.257	0.329	0.297	0.313	0.301	0.293	0.274	0.223
Erro Treino*MV	0.316	0.327	0.315	0.367	0.34	0.349	0.349	0.321	0.352	0.369	0.326	0.328	0.303	0.302	0.367
Erro Simulação*MV	8.314	7.799	8.524	8.143	7.748	9.187	9.422	10.74	9.307	8.498	10.06	10.685	11.401	13.203	18.225
Erro Simulação/PH	1.039	0.975	1.066	1.018	0.969	1.148	1.178	1.343	1.163	1.062	1.258	1.336	1.425	1.650	2.278
Distancia Origem	8.320	7.806	8.530	8.151	7.755	9.194	9.428	10.745	9.314	8.506	10.065	10.690	11.405	13.206	18.229

- Modelo de previsão para a temperatura no corredor

Tabela 17: Modelos de previsão para a temperatura no corredor – teste 1 a 19

Inputs (Tcorr)	Teste 1	Teste 2	Teste 3	Teste 4	Teste 5	Teste 6	Teste 7	Teste 8	Teste 9	Teste 10	Teste 11	Teste 12	Teste 13	Teste 14	Teste 15	Teste 16	Teste 17	Teste 18	Teste 19
Temperatura corredor	0,...,23	0,...,23	0,...,23	0,...,23	0,...,23	0,...,23	0,...,23	0,...,23	0,...,23	0,...,47	0,...,47	0,...,47	0,...,47	0,...,47	0,...,47	0,...,47	0,...,47	0,...,47	0,...,71
Iterações	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60
Neurónios	2	3	4	5	6	7	8	9	10	2	3	4	5	6	7	8	9	10	2
Erro Teste*MV	0.191	0.19	0.186	0.181	0.184	0.187	0.179	0.184	0.188	0.187	0.185	0.182	0.186	0.182	0.177	0.187	0.182	0.18	0.185
Erro Treino*MV	0.18	0.17	0.211	0.213	0.194	0.205	0.187	0.222	0.182	0.203	0.206	0.217	0.209	0.208	0.204	0.214	0.241	0.217	0.208
Erro Simulação*MV	1.798	1.819	1.875	1.845	1.837	1.938	1.91	1.933	1.905	2.067	2.012	1.956	1.974	2.055	1.999	2.232	2.056	2.042	2.144
Erro Simulação/PH	0.225	0.227	0.234	0.231	0.230	0.242	0.239	0.242	0.238	0.258	0.252	0.245	0.247	0.257	0.250	0.279	0.257	0.255	0.268
Distancia Origem	1.807	1.827	1.887	1.857	1.847	1.949	1.919	1.946	1.914	2.077	2.023	1.968	1.985	2.065	2.009	2.242	2.070	2.053	2.154

Tabela 18: Modelos de previsão para a temperatura no corredor – teste 20 a 32

Inputs (Tcorr)	Teste 20	Teste 21	Teste 22	Teste 23	Teste 24	Teste 25	Teste 26	Teste 27	Teste 28	Teste 29	Teste 30	Teste 31	Teste 32
Temperatura corredor	0,...,71	0,...,71	0,...,71	0,...,71	0,...,71	0,...,71	0,...,95	0,...,95	0,...,95	0,...,95	0,...,95	0,...,95	0,...,95
Iterações	60	60	60	60	60	60	60	60	60	60	60	60	60
Neurónios	3	4	5	6	7	8	2	3	4	5	6	7	8
Erro Teste*MV	0.193	0.181	0.181	0.183	0.182	0.184	0.204	0.19	0.183	0.18	0.174	0.177	0.17
Erro Treino*MV	0.217	0.202	0.214	0.208	0.206	0.21	0.241	0.185	0.206	0.215	0.244	0.21	0.213
Erro Simulação*MV	2.228	2.902	2.315	2.348	2.501	2.435	2.729	2.255	2.366	2.574	2.704	2.288	2.658
Erro Simulação/PH	0.279	0.363	0.289	0.294	0.313	0.304	0.341	0.282	0.296	0.322	0.338	0.286	0.332
Distancia Origem	2.239	2.909	2.325	2.357	2.509	2.444	2.740	2.263	2.375	2.583	2.715	2.298	2.667

- Modelo de previsão do CO_2 no corredor

Tabela 19: Modelos de previsão para a concentração de CO_2 no corredor – teste 1 a 19

Inputs (CO2corr)	Teste 1	Teste 2	Teste 3	Teste 4	Teste 5	Teste 6	Teste 7	Teste 8	Teste 9	Teste 10	Teste 11	Teste 12	Teste 13	Teste 14	Teste 15	Teste 16	Teste 17	Teste 18	Teste 19
CO2 corredor	0,...,23	0,...,23	0,...,23	0,...,23	0,...,23	0,...,23	0,...,23	0,...,23	0,...,23	0,...,47	0,...,47	0,...,47	0,...,47	0,...,47	0,...,47	0,...,47	0,...,47	0,...,47	0,...,71
Iterações	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60
Neurónios	2	3	4	5	6	7	8	9	10	2	3	4	5	6	7	8	9	10	2
Erro Teste*MV	33.318	31.71	29.877	30.07	31.362	30.702	31.633	33.752	30.57	32.946	34.493	35.607	35.231	30.444	35.056	31.145	25.941	36.73	35.182
Erro Treino*MV	30.99	37.273	37.778	41.15	36.169	34.246	35.8	35.792	36.181	29.834	32.746	33.523	34.305	33.218	35.811	34.868	39.706	28.613	34.337
Erro Simulação*MV	157.008	159.313	163.346	169.11	174.158	164.515	170.723	170.514	178.583	176.318	209.205	190.363	201.839	198.396	217.282	196.384	204.175	202.148	193.438
Erro Simulação/PH	19.626	19.914	20.418	21.139	21.770	20.564	21.340	21.314	22.323	22.040	26.151	23.795	25.230	24.800	27.160	24.548	25.522	25.269	24.180
Distancia Origem	160.037	163.615	167.658	174.045	177.874	168.042	174.436	174.230	182.211	178.824	211.752	193.292	204.734	201.158	220.213	199.455	208.000	204.163	196.462

Tabela 20: Modelos de previsão para a concentração de CO_2 no corredor – teste 20 a 32

Inputs (CO2corr)	Teste 20	Teste 21	Teste 22	Teste 23	Teste 24	Teste 25	Teste 26	Teste 27	Teste 28	Teste 29	Teste 30	Teste 31	Teste 32
CO2 corredor	0,...,71	0,...,71	0,...,71	0,...,71	0,...,71	0,...,71	0,...,95	0,...,95	0,...,95	0,...,95	0,...,95	0,...,95	0,...,95
Iterações	60	60	60	60	60	60	60	60	60	60	60	60	60
Neurónios	3	4	5	6	7	8	2	3	4	5	6	7	8
Erro Teste*MV	35.433	31.872	35.367	30.634	32.102	30.083	32.817	34.185	32.233	30.201	29.071	31.189	33.17
Erro Treino*MV	30.133	30.289	32.325	38.69	36.038	35.896	32.052	37.995	35.296	38.237	40.43	34.822	40.271
Erro Simulação*MV	199.899	247.176	213.909	227.62	192.563	227.963	196.099	239.833	209.154	223.609	233.629	198.716	195.047
Erro Simulação/PH	24.987	30.897	26.739	28.453	24.070	28.495	24.512	29.979	26.144	27.951	29.204	24.840	24.381
Distancia Origem	202.157	249.025	216.338	230.885	195.906	230.772	198.701	242.824	212.111	226.855	237.101	201.744	199.161

